

# Desarrollo de una aplicación basada en visión 3D para determinar la curva de colapso y la distribución del tamaño de burbujas en espumas asfálticas

Omar Andrés Parra Urrego

Escuela Colombiana de Ingeniería Julio Garavito  
Maestría en Ingeniería Electrónica  
Bogotá D.C., Colombia  
15 de Julio de 2020





# Desarrollo de una aplicación basada en visión 3D para determinar la curva de colapso y la distribución del tamaño de burbujas en espumas asfálticas

Omar Andrés Parra Urrego

Trabajo de grado para optar al título de:  
Magíster en Ingeniería Electrónica  
con énfasis en Control y Automatización

Director:  
Enrique Estupiñán Escalante.

Escuela Colombiana de Ingeniería Julio Garavito  
Maestría en Ingeniería Electrónica  
Bogotá D.C., Colombia  
15 de Julio de 2020



Nota de aceptación:

La tesis de maestría titulada "Desarrollo de una aplicación basada en visión 3D para determinar la curva de colapso y la distribución del tamaño de burbujas en espumas asfálticas", presentada por Omar Andrés Parra Urrego, cumple los requisitos establecidos para optar al título de Magíster en Ingeniería Electrónica.

---

Director del trabajo de grado

---

Jurado

---

Jurado

Bogotá, D.C., 15 de Julio de 2020



*A mis padres Omar y Gladys, por haber  
forjado la persona que soy.*





# Agradecimientos

Agradezco primeramente a Dios por permitirme culminar este proyecto.

Un agradecimiento muy especial a mi tutor, el Ingeniero Enrique Estupiñán Escalante por su guía y aportes, pero sobre todo le agradezco por haber sido mi apoyo, por motivarme y por levantarme el ánimo ante los retos que este trabajo presentó.

Agradezco a la Ingeniera Sandra Campagnoli y a los laboratoristas de suelos por su ayuda durante la toma de videos de las espumas asfálticas.

Agradezco a los demás profesores que con sus conocimientos me han apoyado de una u otra manera durante el desarrollo del proyecto.

Finalmente agradezco a mi esposa Natalia Rincón, quien siempre ha estado a mi lado apoyándome, a mi madre y hermanos quienes han sido mi motor y a mis amigos de la maestría por el apoyo brindado en este proceso.



# Resumen

La caracterización adecuada de asfaltos espumados es un elemento que permite entender propiedades y características que pueden afectar el desempeño de las mezclas en sus distintas aplicaciones.

Los campos de aplicación de procesamiento de imágenes y de visión por computador son cada vez más debido a la versatilidad de las técnicas que se emplean, pues hacen que los procesos sean más certeros y confiables minimizando la intervención humana.

En este trabajo se presenta una herramienta que implementa varios métodos para determinar parámetros convencionales y no convencionales que permiten la caracterización de espumas asfálticas. Se implementa un método semiautomático basado en la geometría de la escena para determinar los parámetros de la curva de colapso, relación de expansión y vida media y técnicas tanto de procesamiento de imágenes como de *Machine Learning*, para estimar la distribución del tamaño de burbujas en espumas asfálticas.

**Palabras clave:** Curva de colapso, Relación de expansión (ER), Vida media (HL), Distribución del tamaño de burbujas (BSD), Machine learning, Procesamiento de imágenes.

# Abstract

The proper foamed asphalt characterization is a key element that allows understanding properties and characteristics that can affect the performance of the mixtures in their different applications.

The application fields of image processing and computer vision are increasing, due to the versatility of the techniques used, since they make the processes more accurate and reliable, minimizing human intervention.

This work presents a tool that implements several methods to determine conventional and unconventional parameters that allow the characterization of foamed asphalt. A semi-automatic method based on scene geometry is implemented to determine the parameters of the collapse curve, expansion ratio and half-life. Techniques based on image processing and Machine Learning are implemented to estimate the bubble size distribution in foamed asphalt.

# Contenido

|   |              |
|---|--------------|
| <b>Agradecimientos</b>  | <b>IX</b>    |
| <b>Resumen</b>  | <b>XI</b>    |
| <b>Contenido</b>  | <b>XIV</b>   |
| <b>Lista de tablas</b>  | <b>XV</b>    |
| <b>Lista de figuras</b>   | <b>XVIII</b> |
| <b>Acrónimos</b>  | <b>1</b>     |
| <b>1. Introducción</b>  | <b>2</b>     |
| 1.1. Antecedentes . . . . .                                     | 2            |
| 1.2. Problema de investigación . . . . .                        | 3            |
| 1.3. Objetivos . . . . .  | 3            |
| 1.3.1. Objetivo General . . . . .                               | 3            |
| 1.3.2. Objetivos específicos . . . . .                          | 4            |
| 1.4. Presentación del documento . . . . .                       | 4            |
| <b>2. Marco teórico</b>   | <b>6</b>     |
| 2.1. Fundamentos de imágenes digitales . . . . .                | 6            |
| 2.1.1. Imagen digital . . . . .                                 | 6            |
| 2.1.2. Procesamiento de imágenes digitales . . . . .            | 6            |
| 2.2. Filtrado espacial . . . . .                                | 7            |
| 2.2.1. Filtros de suavizado . . . . .                           | 8            |
| 2.2.2. Filtros de estadísticos de orden (No lineales) . . . . . | 8            |
| 2.2.3. Filtros de bordes . . . . .                              | 9            |
| 2.3. Calibración . . . . .                                      | 11           |
| 2.3.1. Modelo de una cámara . . . . .                           | 13           |
| 2.3.2. Calibración Estéreo . . . . .                            | 16           |
| 2.3.3. Disparidad . . . . .                                     | 16           |
| 2.4. Método tradicional para estimar ER y HL . . . . .          | 17           |

---

|   |           |
|---|-----------|
| 2.5. Estimación de profundidad con una cámara . . . . .                   | 18        |
| 2.6. Estimación de profundidad con imágenes estéreo . . . . .             | 19        |
| 2.7. Detección de Burbujas . . . . .                                      | 20        |
| 2.8. Machine Learning . . . . .   | 22        |
| <b>3. Metodología</b>   | <b>25</b> |
| 3.1. Elección de algoritmos para detección y conteo de burbujas . . . . . | 25        |
| 3.2. Elección de algoritmos para estimación de altura . . . . .           | 25        |
| 3.3. Elección de equipos . . . . .  | 26        |
| 3.4. Implementación de algoritmos . . . . .                               | 26        |
| 3.5. Validación de resultados . . . . .                                   | 26        |
| 3.5.1. Variables . . . . .  | 27        |
| 3.5.2. Solución de problemas . . . . .                                    | 27        |
| <b>4. Métodos</b>   | <b>28</b> |
| 4.1. Sistema de adquisición y procesamiento de imágenes . . . . .         | 28        |
| 4.2. Recolección de imágenes . . . . .                                    | 29        |
| 4.3. Estimación de altura . . . . .                                       | 30        |
| 4.3.1. Método 2D para estimación de altura . . . . .                      | 30        |
| 4.3.2. Método 3D para estimación de altura . . . . .                      | 31        |
| 4.3.3. Validación de resultados . . . . .                                 | 32        |
| 4.4. Método para encontrar burbujas y estimar la BSD . . . . .            | 32        |
| 4.4.1. Método 1 . . . . .   | 32        |
| 4.4.2. Método 2 . . . . .   | 33        |
| 4.4.3. Validación de resultados . . . . .                                 | 34        |
| <b>5. Resultados y Análisis de Resultados</b>                             | <b>35</b> |
| 5.1. Especificaciones de las espumas asfálticas . . . . .                 | 35        |
| 5.2. Resultados de Curva de Colapso, ER y HL . . . . .                    | 35        |
| 5.2.1. Método 2D . . . . .  | 35        |
| 5.2.2. Método 3D . . . . .  | 40        |
| 5.3. Resultados de la distribución del tamaño de las burbujas . . . . .   | 45        |
| 5.3.1. Método 1 . . . . .   | 46        |
| 5.3.2. Método 2 . . . . .   | 50        |
| 5.3.3. Comparación contra observadores . . . . .                          | 57        |
| 5.4. Rendimiento algoritmos . . . . .                                     | 60        |
| 5.4.1. Métodos para estimar altura . . . . .                              | 60        |
| 5.4.2. Métodos para encontrar burbujas . . . . .                          | 61        |
| 5.5. Interfaz gráfica . . . . .   | 61        |

---

|   |           |
|---|-----------|
| <b>6. Conclusiones y recomendaciones</b>                              | <b>66</b> |
| 6.1. Conclusiones . . . . .   | 66        |
| 6.2. Recomendaciones . . . . .  | 68        |
| <b>Referencias Bibliográficas</b>                                     | <b>69</b> |
| <b>A. Anexo: Evaluación de equipos de adquisición de imágenes</b>     | <b>76</b> |
| <b>B. Anexo: Relación entre p2cm y Altura</b>                         | <b>79</b> |
| <b>C. Anexo: Parámetros de los modelos teóricos</b>                   | <b>82</b> |
| <b>D. Anexo: Imágenes donde no se evidencia presencia de burbujas</b> | <b>83</b> |
| <b>E. Anexo: Resultados adicionales de BSD</b>                        | <b>85</b> |

# Lista de Tablas

|  |    |
|--|----|
| 3-1. Variables estudiadas . . . . .  | 27 |
| 4-1. Características computador portátil . . . . .   | 28 |
| 5-1. Resumen de las especificaciones de las espumas . . . . .                                  | 35 |
| 5-2. Resumen de los RMSE calculados para cada modelo teórico . . . . .                         | 37 |
| 5-3. Resumen de los resultados de ER y HL con método 2D . . . . .                              | 39 |
| 5-4. Resultados BSD . . . . .  | 50 |
| 5-5. Resultados de entrenamiento de clasificadores . . . . .                                   | 52 |
| 5-6. Resumen resultados BSD con SVM . . . . .  | 57 |
| 5-7. Cantidad de aciertos al comparar con Observador 1 . . . . .                               | 59 |
| 5-8. Cantidad de aciertos al comparar con Observador 2 . . . . .                               | 59 |
| 5-9. Cantidad de aciertos al comparar con Observador 3 . . . . .                               | 59 |
| 5-10. Porcentaje de acierto promedio de cada método respecto a cada ob-<br>servador . . . . .  | 60 |
| 5-11. Características del computador de escritorio . . . . .                                   | 60 |
| 5-12. Tiempo de ejecución promedio métodos de para estimar altura . . . . .                    | 60 |
| 5-13. Tiempo de ejecución promedio en segundos de métodos para encontrar<br>burbujas . . . . . | 61 |
| A-1. Evaluación de equipos para adquisición de imágenes . . . . .                              | 76 |
| B-1. Datos medidos . . . . .   | 79 |
| B-2. Regresión y ANOVA de la regresión . . . . .   | 80 |
| C-1. Tabla de parámetros de modelos teóricos . . . . .   | 82 |
| E-1. Resultados BSD con método 1 . . . . .   | 88 |
| E-2. Resultados BSD con método SVM . . . . .   | 91 |
| E-3. Resultados BSD con método NN . . . . .  | 94 |





# Lista de Figuras

|  |    |
|--|----|
| 2-1. Kernel filtros de suavizado . . . . .                         | 8  |
| 2-2. Kernel filtros Prewitt y Sobel . . . . .                      | 10 |
| 2-3. Kernel usados para implementar Laplaciano . . . . .           | 11 |
| 2-4. Objeto de referencia tridimensional. Tomado de [50] . . . . . | 12 |
| 2-5. Objetos de referencia 2D . . . . .                            | 12 |
| 2-6. Modelo de cámara estenopeica . . . . .                        | 14 |
| 2-7. Modelo de cámara estenopeica modificado . . . . .             | 15 |
| 2-8. Modelo de cámara estéreo . . . . .                            | 17 |
| 2-9. Parámetros para estimar altura [9]. . . . .                   | 19 |
| 2-10. Etapas de implementación de ML [51] . . . . .                | 23 |
|  |    |
| 4-1. Montaje cámara y balde para toma de videos . . . . .          | 30 |
| 4-2. Imagen en perspectiva del balde . . . . .                     | 31 |
|  |    |
| 5-1. Imagen en perspectiva del balde . . . . .                     | 36 |
| 5-2. Curvas de colapso mediadas y teóricas . . . . .               | 38 |
| 5-3. Resultado imágenes rectificadas . . . . .                     | 40 |
| 5-4. Parámetros extrínsecos . . . . .                              | 41 |
| 5-5. Parámetros extrínsecos . . . . .                              | 41 |
| 5-6. Parámetros extrínsecos . . . . .                              | 42 |
| 5-7. Composición de imágenes izquierda y derecha . . . . .         | 42 |
| 5-8. Mapa de disparidad usando SGM . . . . .                       | 43 |
| 5-9. Mapa de disparidad usando BM . . . . .                        | 43 |
| 5-10. Imágenes de reconstrucción de la escena . . . . .            | 44 |
| 5-11. Gráficas de profundidad . . . . .                            | 45 |
| 5-12. Resultados para $t = 25$ seg . . . . .                       | 47 |
| 5-13. Resultados para $t = 50$ seg . . . . .                       | 48 |
| 5-14. Resultados para $t = 80$ seg . . . . .                       | 49 |
| 5-15. BSD para los distintos tiempos . . . . .                     | 50 |
| 5-16. Regiones etiquetadas con 1 . . . . .                         | 51 |
| 5-17. Regiones etiquetadas con 0 . . . . .                         | 51 |
| 5-18. Matrices de confusión . . . . .                              | 53 |

|  |    |
|--|----|
| 5-19. Resultados para $t = 25$ seg . . . . .   | 54 |
| 5-20. Resultados para $t = 50$ seg . . . . .   | 55 |
| 5-21. Resultados para $t = 80$ seg . . . . .   | 56 |
| 5-22. BSD para los distintos tiempos . . . . .   | 57 |
| 5-23. Ejemplo de identificación de burbujas realizadas por un observador.<br>Video 80-100 170°C t=50 seg . . . . . | 58 |
| 5-24. Interfaz gráfica para estimar Curva de Colapso, ER y HL . . . . .  | 62 |
| 5-25. Capturas de funcionalidades interfaz de Curva de Colapso . . . . .   | 63 |
| 5-26. Interfaz gráfica para encontrar burbujas y estimar la BSD . . . . .  | 64 |
| 5-27. Capturas de funcionalidades interfaz de burbujas . . . . .   | 65 |
| B-1. Relación entre altura y p2cm . . . . .  | 81 |
| D-1. Imagen de asfalto con 1.5 % de humedad, temperatura de 140°C en<br>t=30 seg . . . . .                         | 83 |
| D-2. Imagen de asfalto con 2.5 % de humedad, temperatura de 150°C en<br>t=40 seg . . . . .                         | 84 |
| D-3. Imagen de asfalto con 3.5 % de humedad, temperatura de 160°C en<br>t=20 seg . . . . .                         | 84 |
| E-1. Resultados método 1 para $t = 5$ seg . . . . .  | 85 |
| E-2. Resultados método 1 para $t = 20$ seg . . . . .   | 86 |
| E-3. Resultados método 1 para $t = 50$ seg . . . . .   | 87 |
| E-4. Resultados método SVM para $t = 5$ seg . . . . .  | 88 |
| E-5. Resultados método SVM para $t = 20$ seg . . . . .   | 89 |
| E-6. Resultados método SVM para $t = 50$ seg . . . . .   | 90 |
| E-7. Resultados método NN para $t = 5$ seg . . . . .   | 91 |
| E-8. Resultados método NN para $t = 20$ seg . . . . .  | 92 |
| E-9. Resultados método NN para $t = 50$ seg . . . . .  | 93 |

# Acrónimos

**AD** Diferencia absoluta -del inglés *Absolute Difference*-.

**BM** *Block Matching*.

**BSD** Distribución del tamaño de burbujas -del inglés, *Bubble Size Distribution*-.

**DT** *Decision Tree*.

**ER** Relación de expansión -del inglés, *Expasion Ratio*-.

**HL** Vida media -del inglés *Half Life*-.

**KNN** *K Nearest Neighbour*.

**ML** *Machine Learning*.

**MSER** Regiones extremas máximamente estables -del inglés *Maximally Stable Extremal Regions*-.

**NN** *Neural Network*.

**RMSE** Raíz del error cuadrático medio -del inglés *Root Mean Square Error*-.

**ROI** Región de interés -del inglés *Region of Interest*-.

**SAD** Suma de diferencias absolutas -del inglés *Sum of Absolute Difference*-.

**SD** Diferencia cuadrada -del inglés *Square Difference*-.

**SGM** *Semi-Global Matching*.

**SURF** *Speeded-Up Robust Features*.

**SVM** *Support Vector Machine*.

**TOF** *Time Of Flight*.

**WMA** Mezclas asfálticas tibias -del inglés *Warm Mix Asphalt*-.

**ZNCC** Correlación cruzada normalizada media cero -del inglés *Zero mean Normalized Cross Correlation*-.

# 1. Introducción

## 1.1. Antecedentes

El asfalto espumado es una técnica usada en ingeniería civil para producir Mezclas asfálticas tibias -del inglés *Warm Mix Asphalt*- (WMA) mediante la adición de agua al asfalto que se encuentra entre 100 y 150 grados centígrados aproximadamente. La técnica contribuye a mejorar el cubrimiento de los agregados por la espuma, la trabajabilidad y la facilidad de compactación de la mezcla, además de aumentar el desempeño frente al deterioro causado por el agua, la deformación permanente y la fatiga de los pavimentos. Adicionalmente, esta técnica permite una mayor tolerancia en la especificación de agregados y por esta razón los procesos constructivos pueden ser de muy alto rendimiento [13, 63].

Por otra parte el uso de asfaltos espumados contribuyen a un aprovechamiento más sustentable de los recursos naturales dada la reducción tanto del consumo de energía como las emisiones de gases de efecto invernadero, requisitos fundamentales dentro del componente ambiental asociado a las obras de construcción, mantenimiento y rehabilitación de carreteras. Estas técnicas son objeto de numerosas investigaciones alrededor del mundo [9].

La ejecución del programa de infraestructura de vías de cuarta generación (4G) que el gobierno nacional de Colombia emprendió en 2013 y que pretende modernizar la infraestructura vial del país con el fin de mejorar la competitividad [25], puede propiciar espacios que permitan implementar nuevas tecnologías en materia de infraestructura.

Para usar de manera eficiente el asfalto espumado, es necesario entender y caracterizar las propiedades y características que puedan afectar la producción y el desempeño de las mezclas.

Para caracterizar espumas de asfalto, convencionalmente se usan parámetros como la Relación de expansión -del inglés, *Expansion Ratio*- (ER) y Vida media -del inglés *Half Life*- (HL), los cuales fueron propuestos en los años 70 [3].

La ER se mide insertando una varilla graduada próxima a la pared del recipiente que recibe la espuma con el fin de registrar la expansión máxima, mientras que con un cronómetro se registra el tiempo en segundos que tarda la espuma en colapsar desde

su volumen máximo, hasta la mitad de este para obtener la HL. Cabe resaltar que las medidas son simples y prácticas, pero los resultados son cuestionables en cuanto a precisión y repetibilidad, pues dependen de la habilidad, experiencia y coordinación del operador [18].

Además de los índices ya mencionados, la curva de colapso o curva de decaimiento y la Distribución del tamaño de burbujas -del inglés, *Bubble Size Distribution* (BSD), proporcionan información adicional para caracterizar espumas de asfalto. Para determinar la curva de colapso y la distribución de burbujas no hay técnicas estandarizadas, pero existen varios trabajos con estudios y propuestas al respecto en donde se han usado sensores de ultra sonido y laser [4, 43] para medir la evolución de la altura de la espuma en el tiempo para así establecer la curva de colapso. Para la determinación de la distribución de burbujas, se ha usado radiografía con rayos X, imágenes térmicas en el espectro del infrarrojo y captura de imágenes con cámaras digitales convencionales [15]. Generalmente se usan instrumentos independientes, uno para determinar la curva de colapso y otro para determinar la distribución de burbujas.

## 1.2. Problema de investigación

Teniendo en cuenta lo expuesto anteriormente y en respuesta a la necesidad de medir múltiples variables de los asfaltos espumados por distintas técnicas, el presente trabajo busca desarrollar una aplicación que permita estimar los parámetros convencionales ER y HL, adicionalmente parámetros no convencionales como la curva de colapso y la distribución del tamaño de burbujas usando visión estereoscópica.

## 1.3. Objetivos

### 1.3.1. Objetivo General

Desarrollar una aplicación para estimar los parámetros de relación de expansión, vida media, la curva de colapso y la distribución del tamaño de burbujas mediante visión estereoscópica, para que el laboratorio de suelos de Ingeniería Civil de la Escuela Colombiana de Ingeniería Julio Garavito mejore la caracterización de asfaltos espumados.

### 1.3.2. Objetivos específicos

- Definir el sistema de adquisición y procesamiento de las imágenes más adecuado a las restricciones y parámetros dados por el laboratorio de suelos.
- Establecer criterios para evaluar los algoritmos que se van a implementar.
- Evaluar algoritmos para medir la profundidad en una imagen y para detectar distintos tipos de burbujas en la superficie de la espuma asfáltica usando visión estereoscópica.
- Implementar en un computador algoritmos para estimar la altura y detección de burbujas de una espuma asfáltica.
- Establecer los formatos de presentación de los resultados de manera que sean útiles para la operación del laboratorio.
- Comparar el rendimiento de la implementación de los algoritmos cuando se implementan en el sistema de procesamiento.
- Implementar la interfaz gráfica para la operación del sistema y para la generación de resultados.

## 1.4. Presentación del documento

En el capítulo 1 se presentan los antecedentes del problema, la pregunta de investigación y los objetivos de este proyecto.

En el capítulo 2 se presenta el marco teórico con los fundamentos teóricos requeridos para el desarrollo del proyecto, así como una revisión de métodos o técnicas que se han usado en referentes cercanos e incluso en trabajos relacionados.

En el capítulo 3 se presenta la metodología que se sigue y con la que se pretende dar cumplimiento a los objetivos planteados.

En el capítulo 4 se describen los métodos que se van a implementar para determinar los parámetros de caracterización mencionados anteriormente. También se define la manera en que los resultados serán validados.

En el capítulo 5 se presenta y discute acerca de los resultados obtenidos en la implementación de los métodos para determinar los parámetros mencionados anteriormente.

En el capítulo 6 se presenta las conclusiones del trabajo de acuerdo con los resultados obtenidos, teniendo presente los objetivos y la pregunta de investigación

planteados. Luego se realizan algunas recomendaciones que pueden servir para trabajos futuros.

Finalmente se encuentran las referencias bibliográficas y anexos.

## 2. Marco teórico

### 2.1. Fundamentos de imágenes digitales

#### 2.1.1. Imagen digital

Una imagen se puede entender como una representación visual plana de un objeto real que se encuentra en 3 dimensiones y se usa para obtener información de lo que allí se encuentra representado.

De manera más formal, una imagen digital es una función de 2 dimensiones  $F(x, y)$ , donde  $x$  y  $y$  son coordenadas en el espacio y  $F$  en cada punto  $(x, y)$  representa el nivel de intensidad o nivel de gris, donde  $F$ ,  $x$  y  $y$  toman valores finitos. Cada elemento que compone la imagen digital se denomina comúnmente como pixel [59, 62] y al manipular una imagen la representación suele ser una matriz de tamaño  $M \times N$  como se observa en 2-1.

$$F(x, y) = \begin{bmatrix} F(1, 1) & F(1, 2) & \dots & F(1, N) \\ F(2, 1) & F(2, 2) & \dots & F(2, N) \\ \vdots & \vdots & \ddots & \vdots \\ F(M, 1) & F(M, 2) & \dots & F(M, N) \end{bmatrix} \quad (2-1)$$

#### 2.1.2. Procesamiento de imágenes digitales

A menudo existe confusión en lo que representa el procesamiento de imágenes pues algunos autores establecen que el procesamiento de imágenes involucra las operaciones que tienen como entrada y como salida una imagen, pero esta definición es un poco limitada, pues una operación como obtener el promedio o el valor máximo de la imagen no sería considerado como procesamiento de imágenes por lo que una definición más acertada sería: todos aquellos procesos cuyas entradas y salidas son imágenes y adicionalmente los procesos que extraen atributos y permiten separación y reconocimiento de objetos individuales [62]

El procesamiento de imágenes se puede dividir en las siguientes etapas aunque no necesariamente se aplica a todas las imágenes [61, 62] :



- **Adquisición de imagen:** Es el proceso de adquirir la información de la escena mediante sensores y la respectiva digitalización.
- **Pre-Procesamiento:** Hace referencia a la forma en como se visualiza la imagen y puede tener procesos como corrección de distorsiones, modificación de brillo, realce, mejora de contraste, reducción de ruido, entre otros.
- **Segmentación:** Es la separación de la imagen en objetos o regiones.
- **Descripción de objetos:** Extracción de características o parámetros de cada objeto como área, diámetro, niveles de intensidad, color, tonalidad, ubicación, entre otros.
- **Clasificación de objetos:** Es la diferenciación de objetos a través de métodos clasificadores.

Las técnicas de procesamiento que se suelen utilizar involucran procesamiento puntual, local o global en el dominio espacial o frecuencial de la imagen, algunas de estas operaciones se describen a continuación.

### **Transformaciones puntuales**

Una transformación puntual de procesamiento de imágenes es aquella que toma como entrada una o varias imágenes y genera una imagen de salida. Las transformaciones más sencillas que se pueden realizar son aquellas que se realizan por pixel, donde el valor del pixel resultante depende únicamente del valor de entrada del pixel, como ejemplo se tiene el ajuste de brillo o contraste, cambios de color, umbralización, transformaciones, rotaciones, entre otras [61, 62].

### **Transformaciones locales**

Son aquellas transformaciones en donde se usa la información de los pixeles vecinos a determinado pixel para determinar el resultado de la operación. Ejemplos de estos tipos de transformaciones son los filtros lineales y no lineales, operaciones de morfología, entre otras [61, 62].

## **2.2. Filtrado espacial**

Las técnicas de filtrado espacial de tipo lineal son aquellas que involucran los valores de pixeles con distintos pesos en una vecindad pequeña alrededor del pixel que se está evaluado para obtener el valor de salida. Una forma común de representar

estas operaciones se muestra en la ecuación 2-2, donde  $w$  es conocida como la matriz de pesos, kernel o máscara y sus valores son los coeficientes del filtro [61, 62]

$$g(x, y) = \sum_{ij} F(x + i, y + j)w(i, j) \quad (2-2)$$

Lo anterior también se puede expresar como una convolución entre la imagen y el kernel  $h$

$$g = F * h \quad (2-3)$$

En los bordes donde no es posible aplicar el kernel se suelen aplicar diversas alternativas (*Padding*) como fijar a cero, repetir el borde o poner un valor de intensidad constante.

### 2.2.1. Filtros de suavizado

Los filtros de suavizado se usan típicamente para reducción de ruido o para suavizar o difuminar la imagen, son conocidos también como filtros promedio o filtros pasabajos. Algunos ejemplos de kernel se muestran en la figura 2-1




Figura 2-1: Kernel filtros de suavizado

Los valores definidos en el kernel de la figura 2-1a son iguales por lo que corresponde a un filtro promedio, mientras que los valores usados en la figura 2-1b son distintos por lo que corresponde a un filtro promedio ponderado donde cada pixel vecino tiene un peso o importancia asociada.

### 2.2.2. Filtros de estadísticos de orden (No lineales)

Los filtros de estadístico de orden son no lineales debido a que el resultado es basado en el orden de los valores de los píxeles dentro de la ventana de vecindad. El filtro más conocido es el filtro de mediana el cual reemplaza el valor del pixel

que se está procesando con la mediana de los valores de intensidad en la vecindad de dicho pixel. El filtro de mediana da muy buenos resultados cuando se tiene ruido tipo impulso o también conocido como ruido sal y pimienta debido a la apariencia de puntos blancos o negros en la imagen [59].

### 2.2.3. Filtros de bordes

Los bordes en una imagen se pueden ver como cambios o transiciones bruscas de intensidad, por lo que una manera de detectar estos cambios es mediante la implementación de la derivada, por lo que la mayor parte de los filtros de bordes están basados en aproximaciones de la primera o segunda derivada. Una definición básica de la primera derivada en una dirección es la función diferencia que se plantea como una derivada parcial debido a que una imagen se puede ver como una función de 2 variables  $F(x, y)$  [59, 61, 62]

$$\frac{\delta F}{\delta x} = F(x + 1) - F(x) \quad (2-4)$$

$$\frac{\delta F}{\delta y} = F(y + 1) - F(y) \quad (2-5)$$

Con lo anterior, la segunda derivada se puede definir como

$$\frac{\delta^2 F}{\delta x^2} = F(x + 1) + F(x - 1) - 2F(x) \quad (2-6)$$

$$\frac{\delta^2 F}{\delta y^2} = F(y + 1) + F(y - 1) - 2F(y) \quad (2-7)$$

### Gradiente

En procesamiento de imágenes las primeras derivadas se implementan mediante la magnitud del gradiente. El gradiente se define como

$$\nabla F = grad(F) = \begin{bmatrix} F_x \\ F_y \end{bmatrix} \quad (2-8)$$

La magnitud del gradiente se define en 2-9, pero por costo computacional es ocasiones la magnitud del gradiente se aproxima por la ecuación 2-10

$$mag(\nabla F) = \sqrt{F_x^2 + F_y^2} \quad (2-9)$$

$$mag(\nabla F) \approx |F_x| + |F_y| \quad (2-10)$$

Cuando se requiere detectar un borde en diagonal se suelen usar las aproximaciones de Roberts, Sobel o Prewitt que se muestran en la figura 2-2

|    |    |   |
|----|----|---|
| 0  | 1  | 1 |
| -1 | 0  | 1 |
| -1 | -1 | 0 |

|    |    |   |
|----|----|---|
| -1 | -1 | 0 |
| -1 | 0  | 1 |
| 0  | 1  | 1 |

(a) Prewitt

|    |    |   |
|----|----|---|
| 0  | 1  | 2 |
| -1 | 0  | 1 |
| -2 | -1 | 0 |

|    |    |   |
|----|----|---|
| -2 | -1 | 0 |
| -1 | 0  | 1 |
| 0  | 1  | 2 |

(b) Sobel

**Figura 2-2:** Kernel filtros Prewitt y Sobel

## Laplaciano

La implementación de la segunda derivada en una imagen se realiza mediante el Laplaciano

$$\nabla^2 F = \frac{\delta^2 F}{\delta x^2} + \frac{\delta^2 F}{\delta y^2} \quad (2-11)$$

Puesto que las derivadas son operaciones lineales, el Laplaciano resulta ser lineal también y se puede definir fácilmente por la ecuación 2-12

$$\nabla^2 F(x, y) = F(x + 1, y) + F(x - 1, y) + F(x, y + 1) + F(x, y - 1) - 4F(x, y) \quad (2-12)$$

Las implementación del Laplaciano generalmente se realiza con los kernel mostrados en la figura 2-3

|   |    |   |
|---|----|---|
| 0 | 1  | 0 |
| 1 | -4 | 1 |
| 0 | 1  | 0 |

a)

|   |    |   |
|---|----|---|
| 1 | 1  | 1 |
| 1 | -8 | 1 |
| 1 | 1  | 1 |

b)

|    |    |    |
|----|----|----|
| 0  | -1 | 0  |
| -1 | 4  | -1 |
| 0  | -1 | 0  |

c)

|    |    |    |
|----|----|----|
| -1 | -1 | -1 |
| -1 | 8  | -1 |
| -1 | -1 | -1 |

d)

**Figura 2-3:** Kernel usados para implementar Laplaciano

El Laplaciano suele usarse para realce de contornos sumando o restando el Laplaciano a la imagen original.

## 2.3. Calibración

Calibración de cámara hace referencia al proceso de obtener los parámetros intrínsecos y extrínsecos de una cámara a partir de un conjunto de imágenes capturadas con dicha cámara.

Los parámetros intrínsecos como su nombre lo indica hacen referencia a parámetros propios de la cámara como la distancia focal, punto principal y parámetros de distorsión.

Los parámetros extrínsecos hacen referencia a parámetros relacionados con la posición de la cámara respecto a la escena o viceversa, como la matriz de rotación y el vector de traslación [66].

Cuando se requiere extraer información relacionada con medidas, ya sea ancho, largo, área, perímetro o profundidad, entre otras, es una buena práctica realizar una calibración a la cámara pues en algunas ocasiones corregir las distorsiones puede ser más que suficiente, pero para el caso en que se requiera extraer información de profundidad se necesitan los parámetros intrínsecos y extrínsecos.


La calibración de cámaras es un tema ampliamente estudiado por lo que existen varios métodos para realizar esta tarea, algunos de estos métodos son:

- Calibración basada en objetos de referencia 3D [64]: La calibración de la cámara se realiza tomando capturas de un objeto tridimensional del cual se conoce bien su geometría. El objeto generalmente consiste de 2 o tres planos que son ortogonales entre si. La calibración se puede llevar a cabo eficientemente pero requiere una configuración elaborada.




Figura 2-4: Objeto de referencia tridimensional. Tomado de [50]

- Calibración basada en objetos de referencia 2D [50]: La calibración se basa en imágenes tomadas de un objeto plano en diferentes orientaciones. Algunos de los objetos planos más usados son el patrón de ajedrez y el patrón de círculos.



(a) Patrón de ajedrez



(b) Patrón de círculos

Figura 2-5: Objetos de referencia 2D

- Calibración basada en una línea 1D [69]: En este método el objeto de calibración usado es elemento recto que puede ser considerado como conjunto de puntos colineales. Es una técnica relativamente nueva y suele ser más utilizado en la calibración de una sola cámara.
- Auto-Calibración [37, 53]: En este método no se requiere un objeto de calibración debido a que la calibración se realiza teniendo en cuenta únicamente correspondencia entre puntos de las imágenes. Este método suele usarse cuando una calibración mediante un objeto de referencia no es posible, pero debido a que se deben estimar un mayor número de parámetros, puede resultar en un problema matemático más complejo.

Para determinar la precisión de la calibración de la cámara, se suele encontrar el error de reproyección, el cual representa la diferencia entre los puntos encontrados y los mismos puntos calculados con el modelo de mundo real obtenido con los parámetros intrínsecos y extrínsecos [56].

El error de reproyección se suele calcular como el error cuadrático medio (ver ecuación 2-13) entre las coordenadas de pixel real  $(x_i, y_i)$  y las proyectadas  $(x_i^{proy}, y_i^{proy})$  [68].

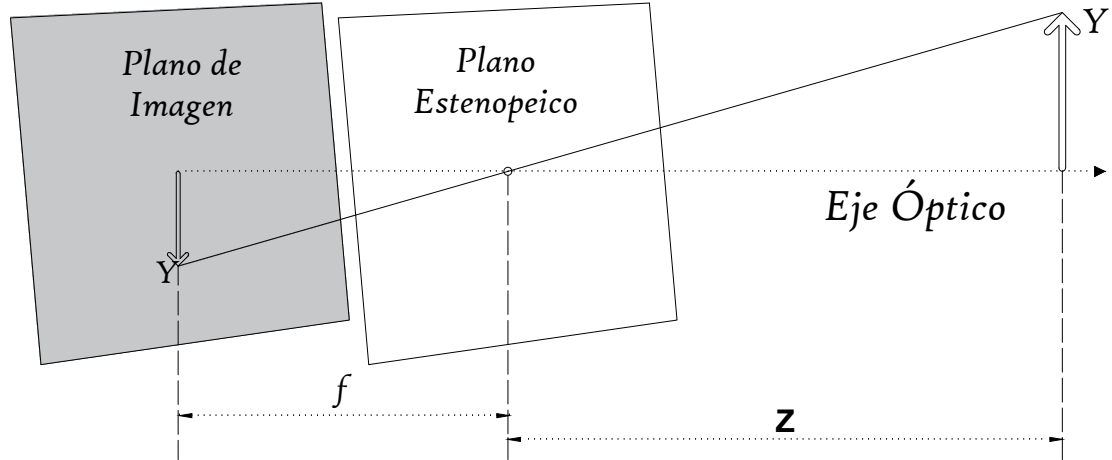
$$\text{error de reproyección} = \sqrt{\frac{1}{n} \sum_{i=1}^n [(x_i - x_i^{proy})^2 + (y_i - y_i^{proy})^2]} \quad (2-13)$$

Donde  $n$  representa la cantidad de puntos o características. El error de reproyección es usado para determinar la precisión de la calibración para una sola cámara o para una cámara estéreo.

### 2.3.1. Modelo de una cámara

El modelamiento de una cámara puede hacerse a partir del modelo básico de una cámara estenopeica en donde la imagen se forma por los rayos de luz que pasan a través de un pequeño orificio como se muestra en la figura 2-6. Se puede determinar por triángulos semejantes que la relación entre cada punto en la imagen y en la escena real están relacionados por la ecuación 2-14 donde  $f$  es la distancia focal,  $Z$  es la distancia de la cámara al objeto,  $Y$  es la altura del objeto o punto de interés y  $y$  la altura proyectada en la imagen. El punto donde se intersectan el eje óptico con el plano de la imagen se conoce como punto principal [10].

$$y = -f \cdot \frac{Y}{Z} \quad (2-14)$$



**Figura 2-6:** Modelo de cámara estenopeica

Una modificación al modelo de cámara estenopeica que permite hacer simplificaciones es tomar el punto estenopeico como centro de proyección y poner el plano de la imagen entre este punto y la imagen como se ve en la figura 2-7, la relación geométrica ahora es la ecuación 2-15. Se debe tener en cuenta que el punto principal puede no estar en el centro de la imagen por lo que se agregarán las componentes  $c_x$  y  $c_y$ . La proyección de un punto  $P = (X, Y, Z)$  en la imagen se puede representar en las ecuaciones 2-16 y 2-17.

$$y = f \cdot \frac{Y}{Z} \quad (2-15)$$

$$x_{img} = f_x \cdot \frac{X}{Z} + c_x \quad (2-16)$$

$$y_{img} = f_y \cdot \frac{Y}{Z} + c_y \quad (2-17)$$

Lo anterior se suele representar de forma matricial como se muestra en la ecuación 2-18, donde  $M$  es la matriz de parámetros intrínsecos de la cámara.



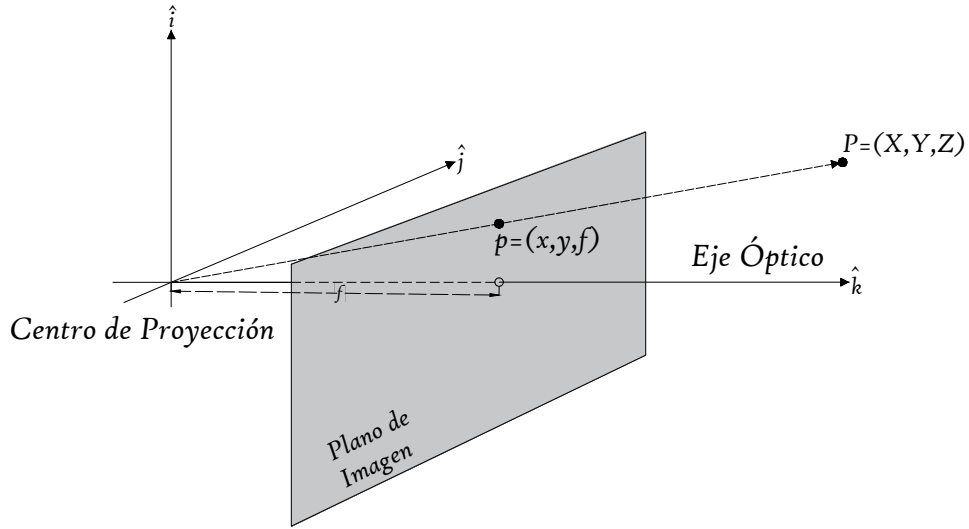


Figura 2-7: Modelo de cámara estenopeica modificado

$$p = MP \quad (2-18)$$

$$\begin{bmatrix} x \\ y \\ w \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \quad (2-19)$$

Las distorsiones causadas por el proceso de fabricación o por los lentes usados deben ser tenidas en cuenta en el modelamiento. Las distorsiones causadas por los lentes usados se conocen como distorsiones radiales y se pueden modelar como una serie de Taylor. En [44] se usa hasta el  $k_3$  término y las ecuaciones de corrección son:

$$x_{\text{corregido}} = x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \quad (2-20)$$

$$y_{\text{corregido}} = y(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \quad (2-21)$$

Cuando el sensor y la lente no se encuentran bien alineados, se producen distorsiones tangenciales que se pueden modelar con dos parámetros adicionales  $p_1$  y  $p_2$  y las ecuaciones de corrección son

$$x_{\text{corregido}} = x + (2p_1y + p_2(r^2 + 2x^2)) \quad (2-22)$$

$$y_{\text{corregido}} = y + (p_1(r^2 + 2y^2) + 2p_2x) \quad (2-23)$$

### 2.3.2. Calibración Estéreo

La visión estereo es un método tradicional para adquirir información 3D de un par de imágenes tomadas desde 2 perspectivas en una misma escena, este método tiene muchas ventajas en términos de costo, rango de operación y fiabilidad. Para extraer características como profundidad o medidas en la escena se hace necesario la calibración de las cámaras [50].

Para las cámaras estereo se obtiene una matriz  $F$ , llamada la matriz fundamental que contiene los parámetros intrínsecos, extrínsecos y distorsiones para cada una de las cámaras y adicionalmente la relación geométrica entre las cámaras [10]. Lo anterior se realiza relacionando capturas simultaneas realizadas a un patrón que puede tener forma de ajedrez o matriz asimétrica de puntos como se muestra en la figura 2-5 [46].

### 2.3.3. Disparidad

Para el cálculo de disparidad y por lo tanto para el cálculo de profundidad se requiere buscar coincidencias entre las imágenes. El proceso es más eficiente si las características en las imágenes están alineadas en líneas horizontales de cada imagen ya que la búsqueda de puntos coincidentes se realiza en una sola dimensión. Conseguir esta alineación suele ser difícil debido a defectos de fabricación de las cámaras por lo que se suele aplicar un proceso llamado rectificación, el cual efectúa rotaciones en las imágenes con el fin de obtener imágenes con características alineadas de forma horizontal[45].

Si las imágenes están perfectamente alineadas, la geometría del sistema se puede describir como se muestra en la figura 2-8 [2]. Donde  $B$  es la distancia entre los centros de proyección de las cámaras,  $f$  es la distancia focal que se asume igual,  $P$  es un punto en el espacio que puede ser visto por las 2 cámaras,  $x^l$  y  $x^r$  son las coordenadas horizontales de proyección del punto  $P$  [45].




Figura 2-8: Modelo de cámara estéreo

La disparidad se puede estimar como la diferencia entre dos puntos coincidentes en las imágenes  $d = x_l - x_r$ . De la figura anterior se puede obtener la relación 2-24

$$Z = f \cdot \frac{B}{x^l - x^r} = f \cdot \frac{B}{d} \quad (2-24)$$

## 2.4. Método tradicional para estimar ER y HL

El asfalto espumado se obtiene a partir de un proceso en el cual dentro de una cámara de expansión se inyecta una cantidad de agua (expresado como porcentaje de la masa de asfalto) y aire comprimido a una masa de asfalto caliente que normalmente se encuentra a una temperatura entre  $100^\circ\text{C}$  y  $150^\circ\text{C}$  [13]. Cuando el agua entra en contacto con el asfalto, se produce un intercambio de energía al punto de convertir las gotas de agua en vapor, el cual es forzado a introducirse en el asfalto dentro de la cámara de expansión. Posteriormente esta mezcla es liberada mediante una válvula y el vapor encapsulado se expande formando burbujas que son contenidas por la tensión superficial del asfalto hasta alcanzar un estado de equilibrio. A medida que la espuma disminuye su temperatura, el vapor dentro de las burbujas se condensa ocasionando el colapso y la desintegración de la espuma. Si el espumado se hace

con menor cantidad de agua, el proceso en general es más lento y la expansión es menor [63].

En el laboratorio, la espuma asfáltica se descarga dentro de un balde, donde un operario mediante una varilla graduada (cada unidad es un múltiplo del volumen inicial del asfalto) mide la expansión y otro operario con un cronómetro registra el tiempo transcurrido. Las mediciones que se realizan son: la relación de expansión que corresponde a la expansión máxima de la espuma respecto al volumen del asfalto sin espumar y la vida media, la cual es el periodo tiempo transcurrido desde el instante en que finaliza la descarga en el balde hasta el momento en que la espuma alcanza la mitad de la expansión máxima [63]. Es claro que las medidas dependen de la habilidad, experiencia y coordinación de los operarios, siendo esta una práctica aceptada y formal que entrega datos suficientes para aproximar una curva [18]. Sin embargo, por precisión y repetibilidad se puede mejorar la toma de las medidas con otras técnicas como visión artificial.

Con los avances en la última década en la capacidad de procesamiento de los dispositivos electrónicos, las áreas de aplicación de visión artificial han ido en aumento en los últimos años. Algunas de estas áreas son metrología de una escena, reconocimiento de objetos, navegación autónoma de robots, asistencia de conducción, control visual, entre muchas otras. La estimación de dimensiones, en particular de altura y profundidad o reconocimiento de formas son algunas de las tareas típicas en muchas de las aplicaciones.

## 2.5. Estimación de profundidad con una cámara

La estimación de profundidad usando una sola cámara es un desafío, pues se está sujeto a distorsiones debidas a la perspectiva y la información del entorno se encuentra en un solo plano. A menudo se recurre a la geometría de la imagen o a patrones conocidos que junto con los parámetros de la cámara permiten establecer relaciones entre la imagen 2D y la vista actual en 3D [21].

Para estimar altura o profundidad usando una sola cámara, se pueden usar cámaras calibradas o cámaras sin calibración, pero se deben incluir modelos de error adecuados [40].

Teniendo en cuenta que a medida que un objeto se aleja de la cámara, su tamaño en pixeles se reduce; si se tiene una medida de referencia en el mismo plano, se pueden estimar las dimensiones de dicho objeto. Basados en esto, en [9], se realizó estimación de altura de espuma asfáltica haciendo uso de la geometría de la escena. Asumiendo que el plano en el que se encuentra la cámara es paralelo al plano del suelo, se determina una curva de calibración entre altura y la razón entre el diámetro

en centímetros y el diámetro en píxeles de la espuma. Se realiza el realce de bordes y luego una segmentación de la espuma manualmente, se estima su diámetro en píxeles, y con la relación entre centímetros y píxeles se calcula la altura.




Figura 2-9: Parámetros para estimar altura [9].

## 2.6. Estimación de profundidad con imágenes estéreo

Para estimar profundidad con imágenes estereoscópicas, la idea es usar múltiples imágenes de la misma escena pero desde diferentes ubicaciones para poderlas relacionar y obtener la disparidad que se define como el desplazamiento relativo de un objeto entre 2 o más vistas. Para un sistema estéreo, se requieren al menos 2 cámaras separadas espacialmente y la disparidad resulta ser una función inversa de la profundidad; esta se encuentra al hacer coincidir los puntos correspondientes de los objetos en cada imagen [55].

Algunos de los métodos de estéreo visión consisten en usar: múltiples cámaras paralelas que enfocan la misma escena, una cámara que realiza un paneo tomando múltiples imágenes moviéndose en una trayectoria que puede ser definida o arreglos de una sola cámara con espejos y lentes que enfocan una escena y producen varias imágenes en el mismo sensor. La idea en cada uno de estos métodos es tener 2 o más imágenes con diferentes puntos de vista para construir la escena en 3 dimensiones [55].

Para construir el mapa de disparidad se debe realizar la correspondencia estéreo (*stereo matching*) entre las imágenes para determinar que puntos de una imagen

corresponden con otra imagen para transformar posiciones 2D en profundidades 3D. Para esto se han desarrollado variados algoritmos que pueden ser clasificados en algoritmos de tipo local o algoritmos de tipo global y dependiendo de su resultado en aquellos que producen una salida densa y los que producen una salida dispersa [70]. En los primeros se realiza una operación por ventanas (un segmento de la imagen) y basados en los valores de intensidad se calcula la disparidad dentro de esta región. Estos métodos son sensibles a las oclusiones (parte de la escena está bloqueada, la continuidad del objeto no se observa). Los algoritmos globales definen la energía obtenida en la imagen y buscan minimizar una función de costo relacionada con la energía [24].

La mayor dificultad en estéreo visión es establecer la correspondencia entre las imágenes o *stereo matching* [54]. Para este proceso se define una función de costo donde los métodos que se usan para determinar la disparidad están basados en Suma de diferencias absolutas -del inglés *Sum of Absolute Difference*- (SAD), Correlación cruzada normalizada media cero -del inglés *Zero mean Normalized Cross Correlation*- (ZNCC), Diferencia absoluta -del inglés *Absolute Difference*- (AD), Diferencia cuadrada -del inglés *Square Difference*- (SD), entre otros [8, 70] y suelen ser combinados con otras técnicas como redes neuronales y programación dinámica con el fin de refinar la disparidad encontrada y obtener mejores resultados [67].

Otra característica a tener en cuenta es el costo computacional, pues que si la implementación del sistema sensor consiste en realizar la toma de imágenes y posteriormente procesar en un computador, los algoritmos globales producen mejores resultados, sin embargo si se pretende procesar en dispositivos móviles o dispositivos con recursos limitados los mejores resultados se obtienen con los algoritmos locales que sacrifican en cierta medida la precisión por un menor tiempo de procesamiento [24].

## 2.7. Detección de Burbujas

El proceso de identificación de objetos en una imagen generalmente requiere una etapa de extracción de características que describen el objeto; por lo que se debe analizar que características son perceptivamente significativas o relevantes. Luego de esto se debe estimar que tan buenas son dichas características y diseñar el algoritmo que obtenga las características [48].

La detección de burbujas mediante técnicas de visión artificial puede llevarse a cabo usando visión 2D. Para una buena detección se requiere un buen contraste entre la superficie de las burbujas y el fluido que las contiene, por lo que es usual usar iluminación para lograr que las burbujas se resalten al reflejar más luz ya sea por

iluminación directa o por iluminación que se tiene atrás de la escena. Al momento de realizar el conteo de las burbujas, se debe tener en cuenta el tiempo de vida de las burbujas, esto es, en cuantos cuadros de imagen permanecen las mismas burbujas [22].

Algunos algoritmos que pueden ser utilizados para la detección de burbujas en general son: Espectro de textura, que consiste en aplicar filtros espaciales que logran obtener características de textura en cada pixel para una posterior clasificación, algoritmo *watershed*, que se basa en la idea de simular flujos de agua en una representación topográfica de la intensidad de la imagen; el algoritmo devuelve la imagen particionada donde todos los puntos en un mismo valle tienen la misma etiqueta (suele tener problemas de sobre segmentación) [26]. Otras técnicas incluyen aproximaciones basadas en detección de bordes, binarización y operaciones morfológicas o gradientes, redes neuronales y clasificadores difusos [26].

En [49] se usa segmentación dinámica que consiste en tener una imagen suavizada de referencia para luego realizar una segmentación inicial por umbralización local y determinar candidatos a burbuja y posteriormente se clasifican dichas regiones basados en el criterio de que una burbuja contiene dos picos de intensidad. En [39] se procesan imágenes de burbujas en masas para pasteles con el fin de obtener la distribución del tamaño de las burbujas. Se aplican filtros inicialmente para reducir el ruido y posteriormente se usa umbralización adaptativa para hacer una segmentación inicial y finalmente aplicar *Watershed*; las imágenes tienen buen contraste y se obtienen buenos resultados en la detección de burbujas.

En [43], se realiza la medición de burbujas en espuma asfáltica, se usa una cámara 2D para capturar imágenes y procesarlas posteriormente. La captura se realiza con flash y dado que las burbujas tienden a ser esféricas, el centro y los bordes de la burbuja se saturan, esta cualidad se aprovecha para detectar la circunferencia externa y medir el diámetro. Cabe resaltar que la detección de las circunferencias se realiza usando la transformada de Hough, pero manualmente se realizan ajustes a la detección y puesto que en los primeros segundos las burbujas son inestables, el análisis se realiza 15 segundos después de la descarga.

Otro método relacionado con imágenes que se ha implementado para medir el diámetro de las burbujas es tomografía computarizada, en la que se congela la espuma asfáltica usando baños de nitrógeno, pero obtener una imagen puede tardar hasta 30 minutos con un alto costo[43].

## 2.8. Machine Learning

En la segunda mitad del siglo XX, *Machine Learning* (ML) evoluciona como una rama de la inteligencia artificial. ML hace referencia a métodos y algoritmos de auto aprendizaje que adquieren su conocimiento a partir de un conjunto de datos llamado conjunto de entrenamiento, con el propósito de realizar predicciones sobre datos nuevos [51]. ML permite resolver problemas mediante la identificación, la clasificación o la predicción y esto lo hace extrayendo modelos predictivos que a partir de los datos van mejorando su desempeño[16].

El objetivo de *Machine Learning* es crear un modelo que permita resolver una tarea dada, este modelo se puede obtener con distintos algoritmos que pueden aprender de un conjunto de datos, se habla de que hay tres tipos de aprendizaje: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje de refuerzo [52].

El aprendizaje supervisado tiene como objetivo crear un modelo para realizar predicciones sobre nuevos datos de entrada a partir de datos de entrenamiento que tienen definida una etiqueta, lo que se espera es que el modelo generado sea capaz de asignar una etiqueta dadas las variables de entrada. Este tipo de aprendizaje puede usarse para resolver problemas de clasificación o problemas de regresión [51, 58].

El aprendizaje no supervisado es aquel que se puede usar cuando no se dispone de un conjunto de entrenamiento con etiquetas sino de un conjunto de datos con estructura desconocida. Al usar técnicas de aprendizaje no supervisado, se explora la estructura de los datos para extraer información relevante sin tener una guía [17, 51]. Suele usarse en aplicaciones que tienen que ver con agrupamientos o perfilado [52].

El aprendizaje de refuerzo está entre el aprendizaje supervisado y el aprendizaje no supervisado, pues en cierta forma existe una supervisión, pero no precisamente en forma de etiqueta que indique el valor de salida deseado. Un algoritmo de aprendizaje de refuerzo recibe la retroalimentación del entorno que se ocasiona al generar una salida a un dato de entrada. La retroalimentación indica la medida en la que la salida conocida como acción, cumple con el objetivo del algoritmo de aprendizaje [57, 58].

En la siguiente figura se presenta un esquema que muestra las etapas de la implementación de ML.



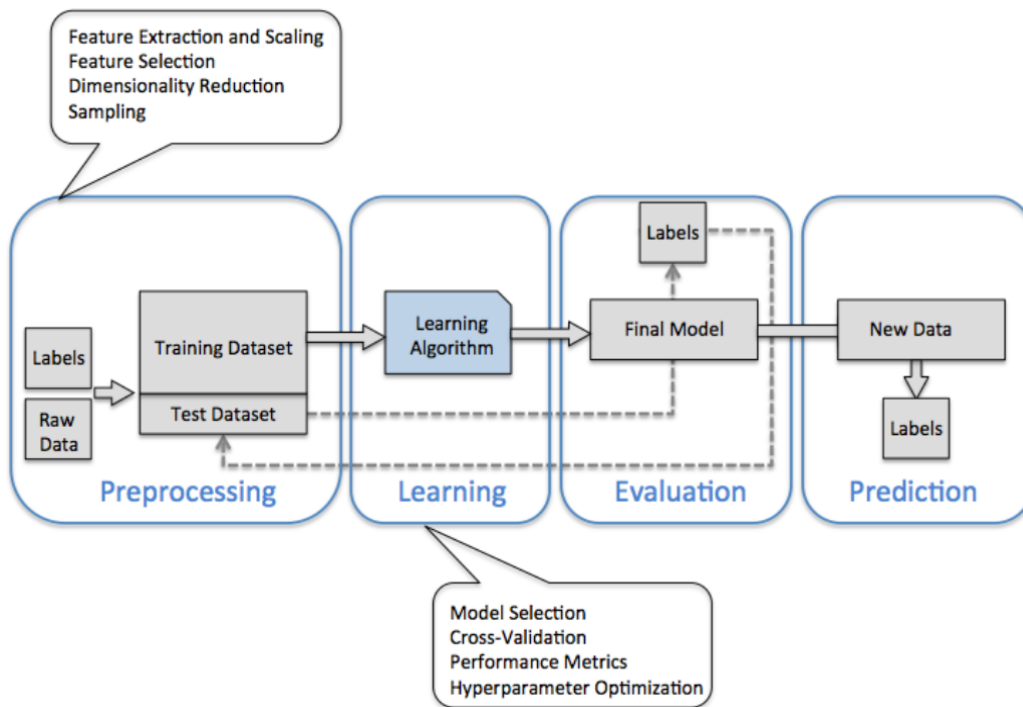


Figura 2-10: Etapas de implementación de ML [51]

Las etapas pueden ser descritas como sigue [51]:

- *Preprocessing*: Los datos casi siempre requieren ajustes para poder ser usados en un algoritmo de aprendizaje, en ocasiones se requiere extraer características que sean significativas para el modelo y generalmente estas características se deben escalar o normalizar para tener un óptimo desempeño del algoritmo.

Cuando se tienen muchas características, puede que algunas de estas estén correlacionadas y por lo tanto pueden ser redundantes, para lo que se puede aplicar técnicas de reducción de dimensionalidad, que además de disminuir el espacio de almacenamiento puede hacer que el algoritmo de aprendizaje se ejecute más rápido.

- *Learning*: Existen diversos algoritmos de ML, y no se puede decir que hay alguno de ellos que es superior a los demás, por lo que en general se deben comparar varios algoritmos y determinar cual es el modelo que tiene mejor desempeño. Uno de los métricas más usadas es la exactitud (*Accuracy*), la cual define la proporción de muestras correctamente clasificadas. Pero también se usan otros parámetros como la sensibilidad y la especificidad, que definen la proporción de muestras positivas y negativas respectivamente clasificadas de forma correcta.

- *Evaluation and prediction*: Cuando se ha seleccionado un modelo que se ajusta bien al conjunto de datos de entrenamiento, se puede usar el conjunto de datos de prueba para estimar que tan bien se desempeña el modelo ante datos nuevos. Si el desempeño es satisfactorio, el modelo puede usarse para predecir nuevos datos. Se debe tener en cuenta que en ocasiones el desempeño sobre el conjunto de datos de prueba puede llegar a ser muy optimista.

Algunos de los métodos más populares en ML son:

- *Neural Network* (NN): Es una técnica de ML bastante popular que es ampliamente usada en problemas de clasificación. Una red neuronal consiste en un arreglo de neuronas implementadas que se dividen típicamente en 3 capas (*layers*), la capa de entrada, la capa oculta y la capa de salida. Las conexiones entre cada nodo tienen pesos que son los que se encargan de generar la salida a una determinada entrada [47].
- *Decision Tree* (DT): Los árboles de decisión consisten de un conjunto de nodos que corresponden a las variables independientes y condiciones que se derivan de cada nodo basadas en una selección jerárquica de las variables independientes modeladas. Estos algoritmos ofrecen simplicidad y facilidad en la visualización de los resultados, en ocasiones si el árbol es muy profundo puede caer fácilmente en sobre ajuste [11].
- *Support Vector Machine* (SVM): las máquinas de soporte vectorial son uno de los algoritmos más populares para resolver problemas de clasificación y es aplicable cuando los datos son linealmente separables [20, 27]. La idea básica es proyectar los datos en un hiper-plano que funcione como una superficie de decisión [47]. Cuando los datos no son linealmente separables se suelen usar *kernels* de funciones de transformación para obtener un hiper-plano donde las características si sean separables. Los kernels que suelen usarse son de tipo radial, polinómicos o sigmoides [11].
- *K Nearest Neighbour* (KNN): la idea básica de esta técnica es que un nuevo caso se va a clasificar en la clase más frecuente, a la cual pertenecen sus  $k$  vecinos más cercanos teniendo en cuenta una métrica de distancia entre las muestras [41]. Suele llamarse *Lazy learner* debido a que no establece una función discriminante a partir de los datos de entrenamiento sino que memoriza el conjunto de datos de entrenamiento [51].

## 3. Metodología

La metodología planteada para el desarrollo del trabajo es no experimental, puesto que no se realizan intervenciones, ni se manipulan variables del experimento [12, 14, 60]. Durante el desarrollo del trabajo se usan conocimientos técnicos de procesamiento de imágenes, visión de máquina y *machine learning* para dar cumplimiento a los objetivos planteados y responder la pregunta de investigación.

Las etapas propuestas para el desarrollo del trabajo son las siguientes:

### 3.1. Elección de algoritmos para detección y conteo de burbujas

En esta etapa se realiza la selección de métodos o algoritmos de procesamiento de imágenes para detectar las burbujas sobre la espuma de asfalto y obtener la distribución del tamaño de las burbujas en instantes de tiempo específicos. También se definen los criterios de evaluación de los algoritmos.

Se realiza inicialmente una revisión en referentes de problemáticas similares donde se ha trabajado con burbujas para determinar características del fluido, características de las burbujas que se producen, aspectos a tener en cuenta en los procesos de adquisición y detección y qué métodos se han empleado para la detección de estas. Luego se realiza una revisión bibliográfica sobre detección de burbujas en asfaltos y se caracteriza el método de adquisición, las imágenes obtenidas, la forma de las burbujas, condiciones y parámetros del problema en cuestión. Se seleccionan los algoritmos a usar, se define los criterios para evaluar los métodos. Para evaluar el desempeño de los métodos, se compara contra máscaras hechas manualmente.

### 3.2. Elección de algoritmos para estimación de altura

En esta etapa se eligen métodos de procesamiento de imágenes para estimar la altura de la espuma en el interior del balde en valores discretos de tiempo y obtener de esta manera la curva de colapso, la relación de expansión y la vida media.

Se realiza una revisión bibliográfica en aplicaciones similares que incluyan medición de altura de fluidos dentro de un recipiente usando una cámara y dos cámaras para determinar los métodos que pueden dar buenos resultados al determinar la altura de la espuma de asfalto. Se definen criterios para evaluar y validar los métodos.

### **3.3. Elección de equipos**

Se realiza una búsqueda en el mercado y se eligen los equipos que se van a usar para la adquisición y el procesamiento de las imágenes. Algunas características tenidas en cuenta son resolución, tamaño, lentes, precio, capacidad, accesorios, facilidad para el desarrollo de la aplicación, integración, entre otras. En la comparación de equipos se valora cualitativamente cada una de las características y se seleccionan los equipos a usar.

En esta etapa también se define el protocolo para la adquisición de las imágenes, se establece la nomenclatura que se va a usar en los archivos de entrada y los resultados y se definen los formatos en los que se deben presentar los resultados para su interpretación y uso.

### **3.4. Implementación de algoritmos**

En esta etapa se realiza la implementación de los algoritmos o métodos seleccionados tanto para estimación de altura como para la detección y conteo de burbujas en el sistema de procesamiento seleccionado.

La prueba de los algoritmos se realiza sobre videos existentes en un repositorio. Cuando se obtengan resultados satisfactorios en estos videos, se realizará la captura de nuevos videos en el laboratorio para verificar el correcto desempeño de los algoritmos.

### **3.5. Validación de resultados**

Los resultados obtenidos con los métodos de visión implementados para la estimación de altura se contrastan contra los resultados existentes al usar el método de la varilla graduada en los videos del repositorio, mientras que los resultados obtenidos para la detección de burbujas se comparan con máscaras creadas manualmente en imágenes al azar de los videos existentes y los nuevos videos.

Con base en los criterios definidos se comparan los algoritmos implementados y se seleccionan los algoritmos que se implementan en la interfaz.

### 3.5.1. Variables

Para el proceso de verificación de los resultados es necesario definir las variables que se van a medir en cada uno de los métodos implementados en la medición de altura y en la detección de burbujas. Las variables se definen en la tabla 3-1

Tabla 3-1: Variables estudiadas

| Variable          | Descripción   |
|-------------------|---|
| Altura            | Define la altura de espuma asfáltica desde el fondo del balde en un instante de tiempo determinado. Medida en centímetros.                      |
| Burbuja           | Depresión o elevación sobre la espuma de asfalto. Medida en unidades.   |
| Tamaño de Burbuja | Define el diámetro de una burbuja. Medido en milímetros.  |
| Curva de colapso  | Define la evolución de la altura de la espuma asfáltica en un periodo de tiempo. Medida en centímetros.   |
| BSD               | Define la distribución del tamaño de las burbujas en determinado instante de tiempo.  |
| ER                | Define la razón entre la altura máxima alcanzada por la espuma asfáltica y su altura inicial. Adimensional.                                     |
| HL                | Define el tiempo medido en segundos que transcurre desde la descarga de la espuma hasta que está alcanza la mitad de la ER. Medida en segundos. |

Cabe aclarar que las variables principales son la altura y el tamaño de burbuja pues con estas se obtienen las demás variables.

### 3.5.2. Solución de problemas

En caso de obtener resultados erráticos se hará una revisión de la implementación de los algoritmos y se realizarán los ajustes a que haya lugar hasta obtener resultados apropiados o establecer la razón por la cual no se obtienen buenos resultados.

## 4. Métodos

En esta sección se describen los métodos escogidos para adquirir y procesar las imágenes de los experimentos de asfaltos espumados en el laboratorio de Suelos y Pavimentos de la Escuela Colombiana de Ingeniería Julio Garavito.

### 4.1. Sistema de adquisición y procesamiento de imágenes

Como parte de otro proyecto se realizaron varios experimentos en el laboratorio donde se evidenció que durante los experimentos se liberan pequeñas partículas de asfalto que se adhieren a los elementos que se encuentren en el lugar. Estas partículas en general no son fáciles de quitar y en algunos casos generan daños en los equipos por lo que se tomó la decisión de involucrar la menor cantidad de equipos y hacer el procesamiento *offline*.

Por facilidad en la implementación se escogió realizar el procesamiento en un computador portátil usando el entorno Matlab; las características del computador utilizado se muestran en la siguiente tabla:

Tabla 4-1: Características computador portátil

| Característica    | Descripción                   |
|-------------------|-------------------------------|
| Marca             | Lenovo                        |
| Procesador        | Core i7, 6ta gen              |
| Tarjeta gráfica   | NVIDIA GeForce 940MX 4GB DDR5 |
| Memoria RAM       | 12 GB DDR4                    |
| Almacenamiento    | SSD 480 GB                    |
| Sistema operativo | Windows 10, 64 bits           |

El equipo de adquisición de imágenes seleccionado fue la cámara Fujifilm Real 3D W3, que cuenta con una resolución espacial de 1280x720 pixeles y puede registrar hasta 24 cuadros por segundo. Para la selección de este equipo se tuvo en cuenta los siguientes criterios:

- Resolución superior a 640x720 pixeles
- Cuadros por segundo superior a 20
- Almacenamiento interno
- Precio inferior a 700 USD
- Acceso a imágenes de cada cámara
- Rango de operación mínimo de 50cm a 1.5m
- Facilidad de uso

En el anexo A se puede encontrar la evaluación de algunos de los equipos encontrados.

## 4.2. Recolección de imágenes

Antes de realizar el ensayo con la espuma se realiza una calibración de la cámara Fujifilm Real 3D W3, la cual tiene una resolución de 1280x720 pixeles. De igual manera se registra la altura a la que se localiza la cámara sobre el trípode, se registra si la toma se hace con zoom óptico o no y se define la iluminación general del laboratorio; se toma 24 cuadros por segundo. Cuando la cámara ya está lista para adquirir las imágenes, se calienta el bitumen en un tanque, se realiza “el disparo” en un balde y este se traslada a la base del trípode bajo la cámara (ver figura 4-1). El video se registra desde antes de colocar el balde bajo la cámara como se muestra en la figura 4-1. Luego de la toma del video se separan los videos para generar los videos izquierdo y derecho y así poder realizar la estimación de la altura y la estimación de la distribución del tamaño de burbujas.




Figura 4-1: Montaje cámara y balde para toma de videos

### 4.3. Estimación de altura

#### 4.3.1. Método 2D para estimación de altura

El método consiste en establecer la relación que existe entre la altura de la espuma asfáltica y el diámetro observado en la imagen de la espuma en pixeles. Para cada video se determina la medida en pixeles del diámetro del balde y del diámetro de la espuma en distintos puntos del colapso como se muestra en la figura 4-2.

Se define la relación entre pixeles y centímetros (p2cm) al dividir el diámetro del balde en cm entre la medida en pixeles obtenida en los distintos puntos del colapso. Tomando dos puntos donde se conoce la altura se determina una relación entre la altura y p2cm (Ver ecuación 4-1) que resulta ser lineal (Ver anexo B), con la cual se estima la altura de la espuma.

$$y = mx + b \quad (4-1)$$

Donde

- $y$ : altura de la espuma






Figura 4-2: Imagen en perspectiva del balde

- $m$ : cambio en la altura por unidad de cambio en la relación entre cm y pixeles
- $x$ : relación entre cm y pixeles
- $b$ : referencia de altura

A cada cuadro del video se le aplica un preprocesamiento que elimina el fondo de la imagen y mejora el contraste para luego marcar de forma manual el diámetro de la masa de espuma asfáltica y poder así obtener la altura de la espuma en distintos puntos del video. A partir de los puntos obtenidos, que representan la evolución del colapso se obtienen la ER y la HL.

### 4.3.2. Método 3D para estimación de altura

Este método hace uso de la información proporcionada por dos cámaras para calcular la disparidad y posteriormente la profundidad de cada punto en la imagen. Con la estimación de la profundidad y teniendo la altura de la cámara se estima la altura de la espuma.

Para aplicar el método, inicialmente se realiza la calibración de las cámaras con ayuda de la herramienta de calibración estéreo de Matlab [7, 36], con lo que se realiza la rectificación de las imágenes al buscar puntos coincidentes y posteriormente se calcula la disparidad.

Dado que la superficie de la espuma no es uniforme, se obtiene el promedio de las disparidades en una región del centro del balde y se realiza la reconstrucción de

la escena para estimar la profundidad de cada punto en la imagen [33]. Luego de tener la información de profundidad y conociendo la altura de la cámara se estima la altura de la espuma.

Para determinar la disparidad se usaron 2 métodos representativos y bien conocidos con los que se había trabajado anteriormente en otro proyecto [42]. Estos algoritmos son *Block Matching* (BM) [23] de tipo local y *Semi-Global Matching* (SGM) [19] que combina características de métodos locales y globales.

### 4.3.3. Validación de resultados

Los resultados obtenidos en cuanto a la curva de colapso serán comparados con 2 modelos exponenciales encontrados en la literatura y que fueron sugeridos por el laboratorio de Suelos y Pavimentos. Se calculará la Raíz del error cuadrático medio -del inglés *Root Mean Square Error*- (RMSE) y si los valores obtenidos son cercanos a 1, se tomará como válido el método.

Los parámetros de ER y HL se estiman a partir de la curva de colapso siendo ER la expansión máxima medida y HL el tiempo que transcurre entre el inicio del experimento y el momento en el que ocurre la mitad de ER. Estos parámetros se validarán con los resultados que se obtienen mediante el método de la varilla para 12 videos en los que se varía la humedad y la temperatura. Se calcula el error relativo, esperando errores menores al 15 %.

## 4.4. Método para encontrar burbujas y estimar la BSD

### 4.4.1. Método 1

Para encontrar las burbujas se hace uso del método Regiones extremas máximamente estables -del inglés *Maximally Stable Extremal Regions*- (MSER) introducido en [18]. El proceso del algoritmo se puede describir de la siguiente manera: 1) se establece que los pixeles con niveles de gris inferiores a un umbral serán negros y los pixeles por encima serán blancos, 2) luego se hace un barrido de negro a blanco moviendo el umbral. Lo que se obtiene es que inicialmente la imagen es toda blanca, pero luego irán apareciendo regiones que pueden ir creciendo hasta que finalmente la imagen se vuelve negra a medida que se aumenta el umbral. 3) El conjunto de todas las regiones conectadas que aparecieron en todo el proceso son las regiones máximas y de estas regiones las que permanecieron estables en determinado rango de intensidades (parámetro del algoritmo) se dice que son máximamente estables y por ende

son las MSER [19]. Cabe resaltar que se les llama extremas porque los pixeles dentro de un MSER tienen una mayor o menor intensidad que los pixeles en el borde.

El proceso para encontrar las burbujas comienza con la mejora de la imagen en cuanto a contraste y bordes, luego se elimina el fondo y se define la Región de interés -del inglés *Region of Interest*- (ROI). Se obtienen las posibles regiones en donde hay burbujas mediante el algoritmo MSER y luego se clasifican dichas regiones teniendo en cuenta un criterio temporal que establece que las regiones que corresponden a burbujas deben mantenerse en varios cuadros consecutivos del video; este criterio se planteó al observar el comportamiento de las burbujas detectadas en varios cuadros. Cuando se tienen las regiones consideradas burbujas se obtienen las medidas de los diámetros de las burbujas en pixeles (parámetro entregado por el algoritmo MSER) y finalmente teniendo como medida de referencia el radio de la espuma, se obtienen los diámetros en milímetros y con esto se realiza un ajuste a una distribución de probabilidad. Algunas de las distribuciones usadas en la literatura son la distribución *Weibull* y la distribución *Gamma* [43]. Se realiza el ajuste de una distribución *Weibull* mediante la función *fitdist* disponible en la herramienta *Statistics and Machine Learning* de Matlab.

El método desarrollado cuenta con parámetros que son ajustables en el proceso de encontrar las burbujas y la BSD, dichos parámetros son los siguientes:

- Mejora de contraste: se puede elegir si se usa o no ecualización de histograma o corrección gamma.
- Realce de bordes: se puede elegir o no entre un filtro laplaciano o resta de cuadros.
- Fondo: Se puede elegir entre eliminar o no el fondo de forma manual o automática.
- Criterio temporal: La cantidad de cuadros en la que debe aparecer una región para ser considerada burbuja puede variarse entre 2 y 10 cuadros.
- Excentricidad: se puede indicar mediante un valor entre 0 y 1.

#### 4.4.2. Método 2

Este método consiste en usar técnicas de ML con el fin de implementar un clasificador de las regiones encontradas por el algoritmo MSER, para luego determinar la BSD.

Inicialmente se realiza una mejora de la imagen, luego se aplica el algoritmo MSER que encuentra regiones en la imagen candidatas a burbujas, luego se aplica el algoritmo SURF para extraer características de cada región; estas características se usan como entrada de un clasificador implementado con técnicas de ML que determina que regiones si corresponden a burbujas. Luego de esto se obtienen los diámetros de estas burbujas en pixeles y teniendo el radio de la espuma como referencia de la imagen se obtienen los diámetros en milímetros y con esto se estima la BSD.

En la literatura se encuentra que se han desarrollado variedad de detectores y descriptores [28, 29, 30, 38]. Uno de los detectores y descriptores más rápidos es el algoritmo llamado *Speeded-Up Robust Features* (SURF), el cual fue introducido en [5]. Este algoritmo tiene características que hacen que el descriptor extraído de un objeto sea distintivo, debido a que es invariante a la escala y rotación del objeto y por lo tanto ofrece una adecuada relación entre complejidad de las características y la robustez a deformaciones comunes en las imágenes [6, 65].

El algoritmo SURF se utiliza en este método para extraer características de un conjunto de burbujas clasificadas manualmente, dichas características se utilizan como base de datos para entrenar los clasificadores de las burbujas.

#### 4.4.3. Validación de resultados

Debido a que la distribución del tamaño de burbujas es un parámetro no convencional, no existe un estándar con el cuál se pueda contrastar los resultados, por lo que la validación se realizará cualitativamente en términos de las burbujas que son encontradas y las que no.

Con el fin de determinar la efectividad de los métodos se realizará una comparación con las burbujas que 3 personas distintas (observadores) logran encontrar manualmente por inspección visual en 6 imágenes.

El método será considerado válido si la media de la BSD disminuye a medida que pasa el tiempo, pues de acuerdo con [43], ese sería el comportamiento esperado.

# 5. Resultados y Análisis de Resultados

En este capítulo se presentan los resultados obtenidos al implementar métodos de visión artificial para obtener la curva de colapso, de la cual se obtienen los parámetros de ER y HL, así como los resultados de la distribución del tamaño de burbujas.

## 5.1. Especificaciones de las espumas asfálticas

Para poder enfocar los métodos a implementar se hace necesario entender y caracterizar el problema, para esto se definieron especificaciones y/o requerimientos específicos sobre los experimentos, las espumas asfálticas y la forma de las burbujas, el resumen se muestra en la tabla 5-1

Tabla 5-1: Resumen de las especificaciones de las espumas

| Parámetro                | Valor         |
|--------------------------|---------------|
| Duración del disparo     | 10 seg        |
| Rango de alturas         | 0-15cm        |
| Diámetro de las burbujas | 2mm a 20mm    |
| Forma de la burbuja      | Esférica      |
| Rango de temperatura     | 140°C a 180°C |
| Contenido de agua        | 1 % a 5 %     |

## 5.2. Resultados de Curva de Colapso, ER y HL

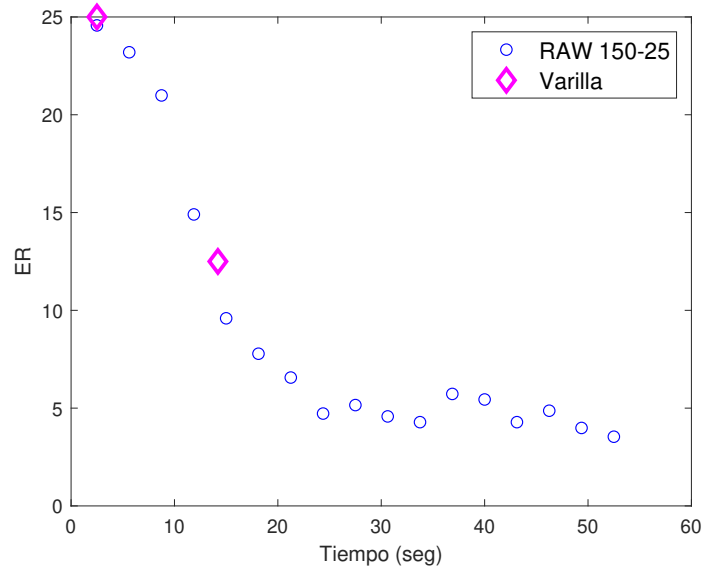
Para realizar las pruebas de los métodos para estimar el colapso se usaron 12 videos donde se tienen tres temperaturas y con cada temperatura 4 porcentajes de humedad.

### 5.2.1. Método 2D

Al procesar los videos con el método 2D se obtuvieron los siguientes resultados.

### Curva de Colapso

Con los puntos obtenidos al aplicar el método 2D, se realiza una gráfica que evidencia el comportamiento de la espuma a través del tiempo como se observa en la figura 5-1.



**Figura 5-1:** Imagen en perspectiva del balde

Cuando se usa el método de la varilla se obtienen únicamente 2 puntos que se usan para estimar el comportamiento del colapso mediante aproximaciones de tipo potencial y sobre todo exponencial, por lo que se realiza la comparación con 2 modelos que se encuentran en la literatura [1] y que fueron sugeridos por el laboratorio de Suelos y Pavimentos adscrito al programa de Ingeniería Civil. Las ecuaciones de estas aproximaciones son:

$$ER = g + \frac{h - g}{1 + 10^{-j(k-t)}} \quad (1) \tag{5-1}$$

$$ER = ae^{-\frac{t}{b}} + ce^{-\frac{t}{d}} + f \quad (2)$$

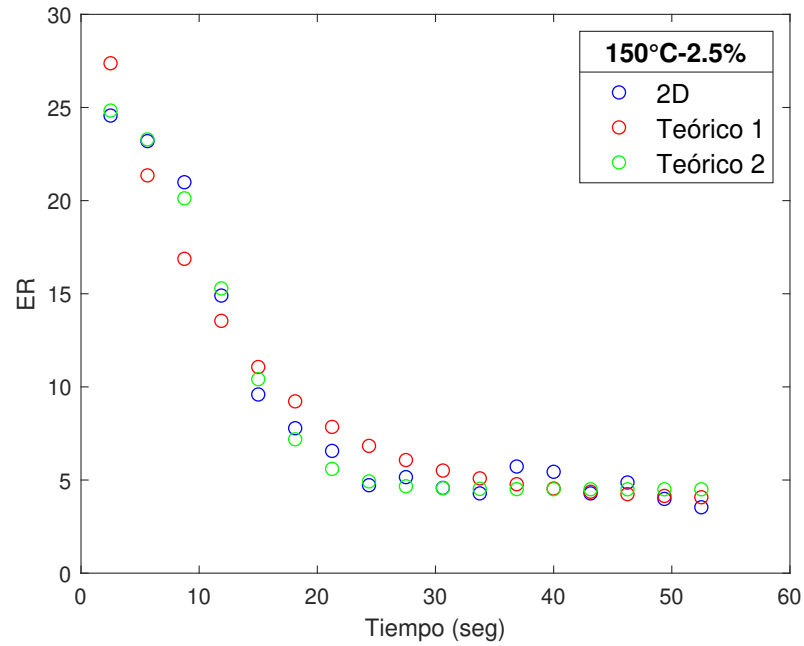
Los parámetros que se requieren en 5-1 se determinan experimentalmente y fueron proporcionados por el laboratorio para cada experimento, en el anexo C se presentan los parámetros usados. Para comparar los resultados obtenidos mediante el método 2D con los modelos teóricos, se realizan las gráficas que permiten dar una valoración

cuantitativa y se calcula la RMSE (Tabla 5-2). Algunas gráficas representativas se presentan en la figura 5-2.

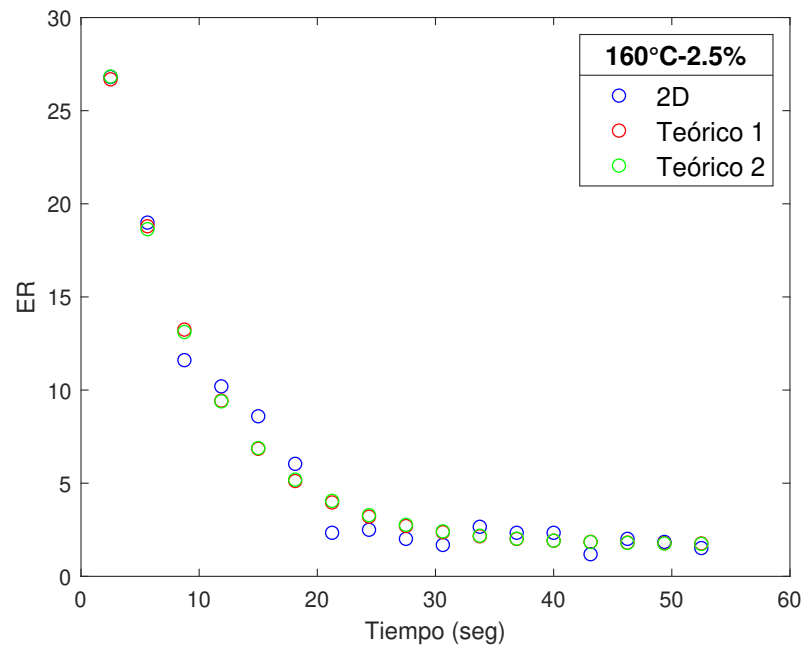
**Tabla 5-2:** Resumen de los RMSE calculados para cada modelo teórico

| T(°C) | % AGUA | RMSE      |           |
|-------|--------|-----------|-----------|
|       |        | Teórico 1 | Teórico 2 |
| 140   | 1.5    | 0.5       | 1.1       |
|       | 2.5    | 1.3       | 1.7       |
|       | 3.5    | 0.9       | 1.2       |
|       | 4.5    | 1.1       | 1.4       |
| 150   | 1.5    | 1.2       | 1.2       |
|       | 2.5    | 0.8       | 1.5       |
|       | 3.5    | 1.0       | 1.5       |
|       | 4.5    | 1.0       | 2.2       |
| 160   | 1.5    | 1.1       | 1.2       |
|       | 2.5    | 0.8       | 0.8       |
|       | 3.5    | 1.8       | 2.8       |
|       | 4.5    | 1.4       | 1.8       |

De la tabla anterior se puede evidenciar que los valores de RMSE son en general menores que 2, lo que significa que la variabilidad de la diferencia entre los valores medidos y los valores teóricos es menor a dos expansiones y en la mayoría de los casos cercana a una expansión. Lo anterior se corrobora al observar las gráficas de las curvas de colapso pues cualitativamente se puede decir que los valores medidos son bastante cercanos a los valores teóricos de los dos modelos considerados. Las mayores diferencias entre los valores medidos y los valores teóricos se pueden deber a los valores atípicos que se obtienen con el método 2D; por ejemplo, en la figura 5-2a se observa que entre el segundo 35 y el segundo 40 hay una subida en la expansión, lo cual no es un comportamiento que pueda presentarse, pues la espuma se encuentra en el final de su colapso.



(a) Temperatura de 150°C y 2.5% de agua



(b) Temperatura de 160°C y 2.5% de agua

**Figura 5-2:** Curvas de colapso mediadas y teóricas



**ER y HL**

Para cada una de las curvas de colapso obtenidas de los 12 videos, se obtienen los datos de ER y HL y se comparan con los datos obtenidos mediante el método de la varilla graduada. El resumen de los resultados obtenidos se muestra a continuación

**Tabla 5-3:** Resumen de los resultados de ER y HL con método 2D

| T(°C) | % AGUA | ER   |      |           | HL   |      |           |
|-------|--------|------|------|-----------|------|------|-----------|
|       |        | Var. | 2D   | Err. Rel. | Var. | 2D   | Err. Rel. |
| 140   | 1.5    | 12.3 | 8.1  | 34.1 %    | 35.2 | 33.0 | 6.3 %     |
|       | 2.5    | 20.0 | 26.5 | 32.5 %    | 21.5 | 26.9 | 25.1 %    |
|       | 3.5    | 22.7 | 22.6 | 0.4 %     | 20.9 | 18.9 | 9.6 %     |
|       | 4.5    | 30.0 | 27.3 | 9.0 %     | 17.7 | 16.4 | 7.3 %     |
| 150   | 1.5    | 16.0 | 14.6 | 8.8 %     | 15.2 | 13.7 | 9.9 %     |
|       | 2.5    | 25.0 | 24.6 | 1.6 %     | 14.2 | 13.4 | 5.6 %     |
|       | 3.5    | 33.0 | 29.1 | 11.8 %    | 11.9 | 13.7 | 15.1 %    |
|       | 4.5    | 35.7 | 34.4 | 3.6 %     | 12.8 | 14.5 | 13.3 %    |
| 160   | 1.5    | 16.0 | 18.4 | 15.0 %    | 12.6 | 10.8 | 14.3 %    |
|       | 2.5    | 28.0 | 26.8 | 4.3 %     | 11.7 | 10.6 | 9.4 %     |
|       | 3.5    | 32.0 | 32.8 | 2.5 %     | 11.3 | 9.9  | 12.4 %    |
|       | 4.5    | 29.3 | 33.8 | 15.4 %    | 10.4 | 10.9 | 4.8 %     |

Para comparar los valores de ER y HL obtenidos mediante el método 2D y el método de la varilla graduada se encontró el error relativo porcentual. Se observa en la tabla que los errores son en general menores al 15 % y en la mayoría de los casos el error es menor al 10 %, lo cual, permite establecer que los resultados son similares y que el método 2D usando procesamiento de imágenes es válido.

Para la estimación de ER, esto es la estimación de la expansión máxima, se observa que 7 de 12 errores se encuentran por debajo del 10 %, 3 entre 11 % y 20 % y 0 entre 21 % y 30 % y 2 entre 31 % y 40 %; cabe destacar que se presenta mayores errores en las temperaturas de 140°C y 160°C y en concentraciones de 1.5 % . En el caso de la estimación del parámetro HL, estimación del punto para el cual ocurre la mitad de ER, se observa que 7 de 12 errores se encuentra por debajo del 10 %, 4 entre 11 % y 20 % y 1 entre 21 % y 30 %; el error mayor se encuentra en la temperatura más baja 140°C.

Las diferencias encontradas pueden ser ocasionadas por diversas fuentes de error con las que se tienen que lidiar en el experimento. Dentro de estas fuentes de error se encuentra el hecho de que las espumas no se comportan siempre de la misma manera y por lo tanto los parámetros de ER y HL pueden variar. Adicionalmente


se debe tener en cuenta que se está comparando con el método de la varilla que puede tener errores humanos. También hay que considerar que existe un retardo, no medido, causado por el traslado del balde hasta posicionarlo debajo de la cámara, lo que puede ocasionar la pérdida del momento exacto en el que ocurre la ER.

### 5.2.2. Método 3D


En esta sección se muestran los resultados obtenidos de la calibración de la cámara, así como los resultados de la implementación del método para estimar altura usando la información de las 2 cámaras.

#### Resultados de calibración

Para la calibración de las cámaras se usó un conjunto de 29 imágenes tomadas a un patrón de ajedrez, con el que se obtuvo un error de reproyección promedio de 0.27 píxeles. En la figura 5-3a se muestra un ejemplo de las imágenes de calibración usadas y en la figura 5-3b se muestra las mismas imágenes rectificadas.



(a) Imágenes izquierda y derecha



(b) Imágenes izquierda y derecha rectificadas

**Figura 5-3:** Resultado imágenes rectificadas

En la figura 5-4 se presentan los parámetros extrínsecos encontrados para cada imagen. Las distancias y posiciones de los objetos mostrados concuerdan con la forma en que se adquirieron las imágenes.

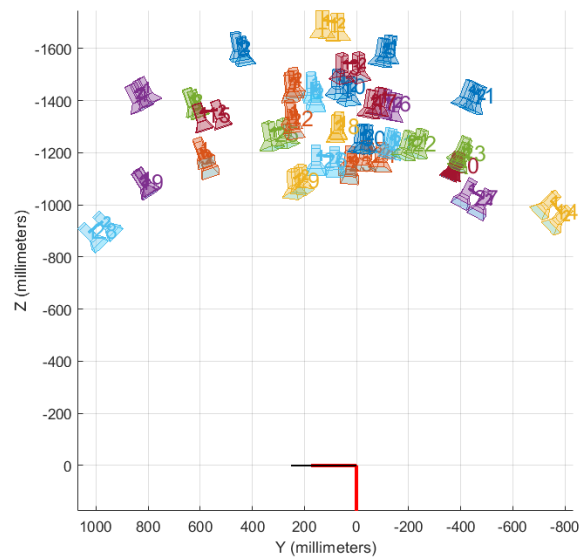


Figura 5-4: Parámetros extrínsecos

### Resultados de la implementación


A continuación se muestran los resultados obtenidos al implementar el método basado en la disparidad para estimar la altura de la espuma. En las figuras 5-5 y 5-6 se muestra las imágenes izquierda y derecha originales y rectificadas respectivamente. Se observa que las imágenes rectificadas están alineadas por lo que para corroborarlo se obtiene la figura 5-7 que representa la composición de las imágenes rectificadas.



Figura 5-5: Parámetros extrínsecos




**Figura 5-6:** Parámetros extrínsecos




**Figura 5-7:** Composición de imágenes izquierda y derecha

Luego de tener las imágenes izquierda y derecha rectificadas se obtiene la disparidad mediante dos métodos que tiene implementados la plataforma Matlab, esto son: un método con características globales y locales, *Semi-global matching* y un método local, *Block matching*. Los mapas de disparidad obtenidos se pueden apreciar en las figuras 5-8 y 5-9.

Los resultados no son muy buenos, pues por ejemplo para el caso en que se usa SGM no se logran distinguir formas en la imagen y aunque cuando se usa BM se puede reconocer el borde del balde, el interior del balde no es reconocible.



**Figura 5-8:** Mapa de disparidad usando SGM

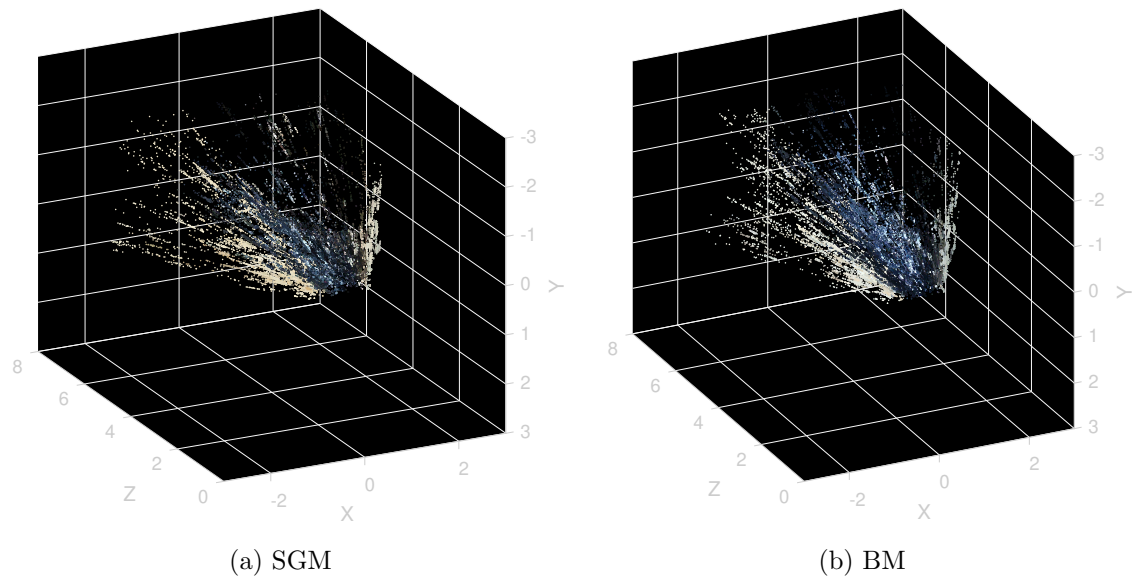


**Figura 5-9:** Mapa de disparidad usando BM

Una vez obtenida la disparidad, se realiza la reconstrucción de la escena con el fin de verificar las distancias (ver figura 5-10), pero se observa que las medidas del eje Z que corresponden a la profundidad no concuerdan con la realidad, pues hay valores superiores a 2 metros y la cámara se fijó a 90cm del suelo, es decir, los valores de profundidad deberían estar entre 56cm y 90cm. Al observar la figura 5-7, se entiende que las imágenes generadas por cada cámara se encuentran poco traslapadas (donde coinciden la parte azul y la roja), lo que hace que la estimación de la disparidad no sea adecuada. Esto se debe a la distancia a la que se encuentran las cámaras y que obligaría a alejar la cámara de la espuma para tener una mejor estimación de la disparidad, pero afectaría negativamente la estimación de las burbujas.

Al procesar todo el video, se obtienen valores de profundidad en distintos instantes de tiempo. Las gráficas de estos valores contra el tiempo se muestran en la figura 5-11. El comportamiento esperado de la profundidad es que vaya aumentando a medida que el tiempo aumenta, pues la espuma va colapsando y por lo tanto se aleja de la cámara. Con ninguno de los métodos para estimar disparidad se obtiene un comportamiento congruente por lo que el método no se considera válido.

Adicionalmente a lo mencionado, se debe tener presente que el cálculo de la disparidad es un método que depende de la intensidad y en las imágenes de espumas asfálticas la intensidad no es uniforme aún cuando se trate de un mismo elemento como por ejemplo la pared interior del balde, pues cuando la luz incide sobre la superficie del asfalto y particularmente sobre la superficie de las burbujas, esta se refleja en varias direcciones ocasionando cambios en la intensidad y por lo tanto causando errores en el cálculo de disparidad.



**Figura 5-10:** Imágenes de reconstrucción de la escena




Figura 5-11: Gráficas de profundidad

### 5.3. Resultados de la distribución del tamaño de las burbujas

Al analizar los 12 videos usados anteriormente se encuentra que en estos asfaltos las burbujas que se producen son muy pocas y debido a la distancia a la que se fijó la cámara, estas son poco reconocibles, por lo que se hace necesario capturar nuevos videos usando zoom con otros asfaltos en donde si se evidencia la presencia de burbujas. En el anexo D se muestran algunas imágenes de distintos videos en donde se evidencia lo mencionado anteriormente.

En la sección 5.3.1 se muestran los resultados obtenidos en cuanto a la detección de burbujas y distribución del tamaño de burbujas, al implementar el método 1 en el asfalto MPI 80-100 con 2.5% de contenido de agua y una temperatura de 170°C, para los tiempos: 25, 50 y 80 segundos.

Luego, en la sección 5.3.2 se muestra el proceso de extracción de características, los resultados del entrenamiento de distintas técnicas de ML con aprendizaje supervisado y la elección del clasificador con mejor desempeño. Seguidamente se muestran los resultados obtenidos en cuanto a la detección de burbujas y distribución del tamaño de burbujas, al implementar el método 2 con el clasificador elegido en las mismas imágenes en las que se implementó el método 1.

Finalmente en la sección 5.3.3, para determinar la efectividad de los métodos implementados, se realiza una comparación de la cantidad de burbujas que los diferentes métodos encuentran, respecto a la cantidad de burbujas que 3 observadores identifiquen por inspección visual de la imagen. Este proceso se realiza en las 3 imágenes ya

mencionadas y para 3 imágenes adicionales de otro video. Este video corresponde a un asfalto MPI 60-70 con 2.5 % de contenido de agua y una temperatura de 160°C, para los tiempos: 5, 20 y 50 segundos.

### 5.3.1. Método 1


#### Resultados obtenidos al implementar el método 1

En las figuras 5-12a, 5-13a y 5-14a se presentan los resultados obtenidos de las burbujas que se encuentran en los distintos instantes de tiempo usando el método 1. Se puede apreciar que en general los círculos rojos corresponden a burbujas y además las burbujas que no son detectadas por el algoritmo son pocas, por lo que cualitativamente el método es bueno. También se observa que existen algunas regiones marcadas como una burbuja que no corresponden a una burbuja, es decir, son errores de detección. Dichos errores de detección son regiones donde hay aglomeración de burbujas o regiones con nivel de intensidad alto que se consideran regiones MSER y que cumplen con el criterio de ser regiones constantes en el tiempo.

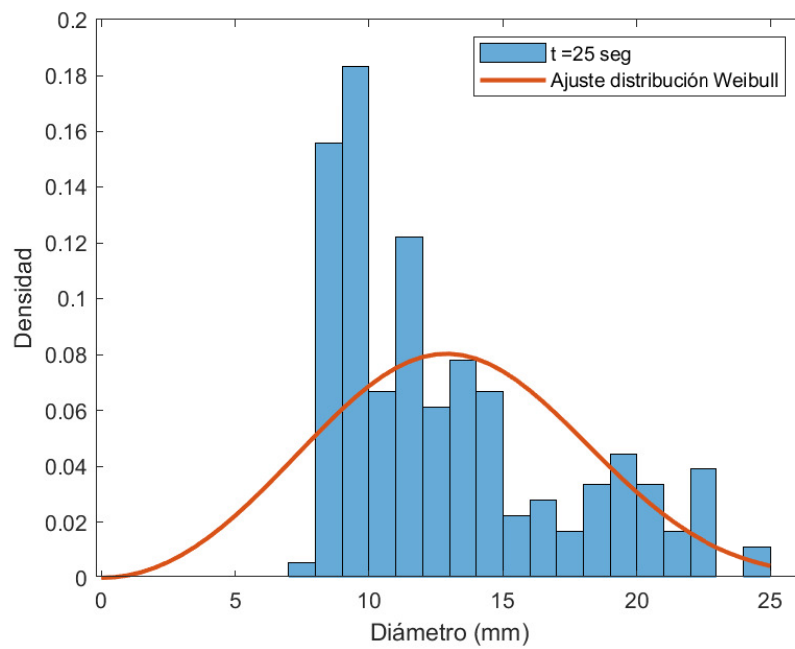
A partir de los diámetros de las burbujas encontradas se realiza un gráfico de barras, el cual da una idea de la distribución de las burbujas y posteriormente se determina la distribución del tamaño de las burbujas ajustando una distribución Weibull a los datos de los diámetros de las burbujas, estos resultados se muestran en las figuras 5-12b, 5-13b y 5-14b.

A pesar de que no existe un estándar con el cual comparar los resultados obtenidos, estos concuerdan con la teoría pues en [43] se dice que para un asfalto sin aditivos el comportamiento esperado es que inicialmente aparezcan las burbujas más grandes y que medida que pasa el tiempo las burbujas tiendan a ser más pequeñas y en mayor cantidad, pues al inicio del colapso se libera mayor energía que al final del colapso. Lo anterior se evidencia en la figura 5-15 y en la tabla 5-4 pues la cantidad de burbujas encontradas aumenta y la media del diámetro de la burbuja disminuye con el tiempo.






(a) Burbujas encontradas




(b) BSD

**Figura 5-12:** Resultados para  $t = 25$  seg




(a) Burbujas encontradas




(b) BSD

**Figura 5-13:** Resultados para  $t = 50$  seg



(a) Burbujas encontradas



(b) BSD

**Figura 5-14:** Resultados para  $t = 80$  seg




Figura 5-15: BSD para los distintos tiempos

Tabla 5-4: Resultados BSD

| Tiempo (seg) | # Burbujas | Diámetro promedio (mm) |
|--------------|------------|------------------------|
| 25           | 180        | 13.1455                |
| 50           | 258        | 12.0312                |
| 80           | 356        | 10.4646                |

### 5.3.2. Método 2

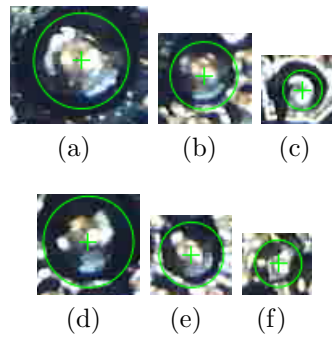
#### Creación de base de datos

Se implementó *machine learning* mediante aprendizaje supervisado para lo que se creó una base de datos con 5089 muestras de 64 características, donde 1923 muestras corresponden a regiones que son burbujas y 3166 a regiones que no son burbujas.

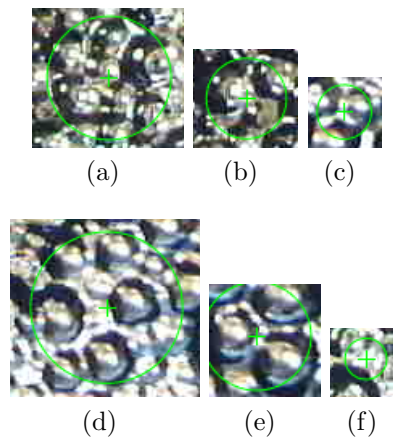
Para extraer las características se aplica inicialmente el método MSER que entrega regiones candidatas a burbujas en una imagen; a estas regiones se les aplica el método SURF, el cual se encarga de extraer en vector con 64 características para cada región. De forma manual se procesaron 5089 regiones a las que se les puso la etiqueta 1, en

caso de que la región correspondiera a una burbujas y la etiqueta 0, en caso de que la región no correspondiera a una burbuja.

El resultado que se espera obtener es un clasificador que a partir de las características extraídas por el algoritmo SURF en una región considerada MSER, pueda determinar si dicha región corresponde o no a una burbuja. En la figura 5-16 se muestran ejemplos de regiones etiquetadas como 1 y en la figura 5-17 se muestran ejemplos de regiones etiquetadas como 0.



**Figura 5-16:** Regiones etiquetadas con 1



**Figura 5-17:** Regiones etiquetadas con 0

### Elección del clasificador

Mediante las herramientas *Classification Learner* [35] y *Deep Network designer* [34] de Matlab, se realiza el entrenamiento supervisado de distintos algoritmos, teniendo como método de validación *cross-validation* y usando como conjunto de entrenamiento el conjunto de características mencionado en la sección anterior.

La herramienta *Classification Learner* entrega únicamente los resultados del desempeño en el conjunto total de datos, no entrega los resultados del desempeño de los

algoritmo para los conjuntos de entrenamiento, validación y prueba, por lo que los resultados que se muestran corresponden al desempeño sobre el conjunto de datos completo.

En la tabla 5-5 se muestran los resultados del entrenamiento de los clasificadores y se calculan los parámetros de desempeño: exactitud, sensibilidad y especificidad. Se observa que los mejores resultados se obtienen para la SVM y la NN.

En la figura 5-18 se muestran las matrices de confusión generales para los 2 mejores clasificadores que fueron una SVM no lineal con kernel cuadrático y una NN con 10 neuronas en la capa oculta.

Los parámetros de exactitud, sensibilidad y especificidad de la SVM y la NN son muy similares por lo que se espera que los dos clasificadores tengan un desempeño similar. Se decide implementar ambos clasificadores y por simplicidad al método que usa la SVM y al método que usa la NN se les conocerá de aquí en adelante como el método SVM y el método NN respectivamente.

**Tabla 5-5:** Resultados de entrenamiento de clasificadores

| Método              | TN <sup>1</sup> | FN <sup>2</sup> | FP <sup>3</sup> | TP <sup>4</sup> | Exac.  | Sensi. | Espec. |
|---------------------|-----------------|-----------------|-----------------|-----------------|--------|--------|--------|
| Medium Tree         | 2720            | 446             | 459             | 1464            | 82.2 % | 76.6 % | 85.6 % |
| Linear Discriminant | 2886            | 280             | 264             | 1659            | 89.3 % | 85.6 % | 91.6 % |
| Kernel Naive Bayes  | 2777            | 389             | 297             | 1626            | 86.5 % | 80.7 % | 90.3 % |
| Quadractic SVM      | 2938            | 228             | 254             | 1669            | 90.5 % | 88.0 % | 92.0 % |
| Medium KNN          | 2932            | 234             | 363             | 1560            | 88.3 % | 87.0 % | 89.0 % |
| Neural Network.     | 2948            | 259             | 218             | 1664            | 90.6 % | 86.5 % | 93.1 % |

<sup>1</sup> True Negative.

<sup>2</sup> False Negative.

<sup>3</sup> False Positive.

<sup>4</sup> True Positive.





Figura 5-18: Matrices de confusión


## Resultados al implementar el método 2

Al analizar los resultados obtenidos para cuando se usa la SVM o la NN como clasificador se observa que los resultados son muy similares por lo que en las figuras 5-19a, 5-20a y 5-21a se presentan los resultados obtenidos de las burbujas que se encuentran en los distintos instantes de tiempo usando la SVM como clasificador (resultados adicionales se muestran en en anexo E). Se evidencia que la detección de burbujas es más precisa que en el caso del método 1, pues hay menos detecciones falsas, pero hay algunas burbujas que no son encontradas.

A partir de las burbujas encontradas se determina la distribución del tamaño de burbujas que se muestran en las figuras 5-19b, 5-20b y 5-21b. Al igual que en el método 1 se observa que los resultados para la BSD concuerdan con la teoría pues la cantidad de burbujas aumenta con el tiempo y la media tiende a ser menor. Lo anterior se evidencia en la figura 5-22 y en la tabla 5-6.




(a) Burbujas encontradas




(b) BSD

**Figura 5-19:** Resultados para  $t = 25$  seg






(a) Burbujas encontradas




(b) BSD

**Figura 5-20:** Resultados para  $t = 50$  seg



(a) Burbujas encontradas



(b) BSD

**Figura 5-21:** Resultados para  $t = 80$  seg




Figura 5-22: BSD para los distintos tiempos

Tabla 5-6: Resumen resultados BSD con SVM


| Tiempo (seg) | Burbujas SVM | Diámetro promedio SVM (mm) | Burbujas NN | Diámetro promedio NN (mm) |
|--------------|--------------|----------------------------|-------------|---------------------------|
| 25           | 122          | 10.9603                    | 119         | 10.7073                   |
| 50           | 188          | 10.2083                    | 186         | 10.3444                   |
| 80           | 243          | 8.4749                     | 246         | 8.5221                    |

### 5.3.3. Comparación contra observadores

Como se mencionó anteriormente, no hay un estándar que permita indicar la bondad de los resultados obtenidos con los métodos para encontrar burbujas, por lo que se realiza una validación de los resultados obtenidos en cuanto a la cantidad de burbujas encontradas por los métodos contra las burbujas que pueden encontrar tres observadores por inspección visual en la imagen. Para esto se usaron 6 imágenes: 3 imágenes corresponden a un video de un asfalto MPI 80-100 en 25, 50 y 80 segundos,

las otras 3 imágenes corresponden a un video de un asfalto MPI 60-70 en 5, 20 y 50 segundos.

En la figura 5-23 se muestra un ejemplo de las detecciones realizadas por un observador, se marcan aquellas burbujas que están bien formadas y que se logran reconocer visualmente.



**Figura 5-23:** Ejemplo de identificación de burbujas realizadas por un observador. Video 80-100 170°C t=50 seg

En las tablas 5-7, 5-8 y 5-9 se muestran los resultados obtenidos en el recuento de burbujas encontradas por el observador, la cantidad de burbujas encontradas y el número de aciertos o coincidencias de cada método.

Se evidencia que hay diferencias entre la cantidad de burbujas que los observadores encontraron y la cantidad de burbujas que encuentran los métodos, pues en general la cantidad de burbujas que encuentran los observadores es mayor a la cantidad de burbujas que encuentran los métodos. Además de esto se encontró que las coincidencias o el porcentaje de aciertos en promedio es cercano al 50% como se observa en la tabla 5-10, siendo el método que usa como clasificador una SVM el que mejor desempeño tiene. Cabe mencionar que es posible que la efectividad de los métodos pueda llegar a ser mayor que el porcentaje de aciertos que se encontró pues el observador no identifica todas las burbujas que hay en la imagen y los métodos puede que sí. Lo anterior se apoya en que al analizar las tablas 5-7, 5-8 y 5-9 se evidencia que cuando el observador identifica un mayor número de burbujas la cantidad de aciertos incrementa.

La diferencia entre el método SVM y el método NN no es mayor a 2 puntos porcentuales, lo cual era esperado pues los parámetros de exactitud, sensibilidad y

especificidad de estos clasificadores con los datos de entrenamiento fue muy similar.

Las mayores diferencias se presentaron para el método 1, esto se debe a que este método en ocasiones sobre estima el diámetro de las burbujas y al momento de verificar las coincidencias con los observadores se descartaron algunas burbujas, pues presentaban un diámetro mucho mayor.

A partir de los resultados obtenidos por los métodos también se logra determinar que el diámetro mas pequeño que se puede encontrar es de 19 píxeles, dependiendo de la altura de la espuma y de la cámara, el diámetro mínimo en milímetros puede variar.

**Tabla 5-7:** Cantidad de aciertos al comparar con Observador 1

| Video        | Tiempo | Obs 1 | Método 1 |      | SVM      |      | NN       |      |
|--------------|--------|-------|----------|------|----------|------|----------|------|
|              |        | Tot.  | Aciertos | Tot. | Aciertos | Tot. | Aciertos | Tot. |
| 80-100 170°C | 25     | 156   | 70       | 180  | 67       | 122  | 63       | 119  |
|              | 50     | 190   | 103      | 258  | 91       | 188  | 87       | 186  |
|              | 80     | 302   | 139      | 356  | 126      | 243  | 118      | 246  |
| 60-70 160°C  | 5      | 112   | 56       | 221  | 66       | 144  | 64       | 146  |
|              | 20     | 170   | 89       | 274  | 110      | 215  | 107      | 207  |
|              | 50     | 216   | 117      | 343  | 152      | 281  | 136      | 271  |

**Tabla 5-8:** Cantidad de aciertos al comparar con Observador 2

| Video        | Tiempo | Obs 2 | Método 1 |      | SVM      |      | NN       |      |
|--------------|--------|-------|----------|------|----------|------|----------|------|
|              |        | Tot.  | Aciertos | Tot. | Aciertos | Tot. | Aciertos | Tot. |
| 80-100 170°C | 25     | 177   | 62       | 180  | 71       | 122  | 70       | 119  |
|              | 50     | 215   | 97       | 258  | 112      | 188  | 109      | 186  |
|              | 80     | 368   | 141      | 354  | 179      | 243  | 176      | 246  |
| 60-70 160°C  | 5      | 158   | 67       | 221  | 80       | 144  | 79       | 146  |
|              | 20     | 209   | 98       | 274  | 129      | 215  | 124      | 207  |
|              | 50     | 213   | 124      | 343  | 140      | 281  | 136      | 271  |

**Tabla 5-9:** Cantidad de aciertos al comparar con Observador 3

| Video        | Tiempo | Obs 3 | Método 1 |      | SVM      |      | NN       |      |
|--------------|--------|-------|----------|------|----------|------|----------|------|
|              |        | Tot.  | Aciertos | Tot. | Aciertos | Tot. | Aciertos | Tot. |
| 80-100 170°C | 25     | 181   | 70       | 180  | 77       | 122  | 75       | 119  |
|              | 50     | 225   | 108      | 258  | 124      | 188  | 120      | 186  |
|              | 80     | 360   | 155      | 368  | 174      | 243  | 166      | 246  |
| 60-70 160°C  | 5      | 198   | 90       | 221  | 93       | 144  | 91       | 146  |
|              | 20     | 251   | 121      | 274  | 151      | 215  | 139      | 207  |
|              | 50     | 326   | 156      | 343  | 185      | 281  | 183      | 271  |

**Tabla 5-10:** Porcentaje de acierto promedio de cada método respecto a cada observador

| Método   | Obs 1 | Obs 2 | Obs 3 |
|----------|-------|-------|-------|
| Método 1 | 50 %  | 44 %  | 48 %  |
| SVM      | 54 %  | 53 %  | 55 %  |
| NN       | 52 %  | 52 %  | 53 %  |

## 5.4. Rendimiento algoritmos

Se comparó el rendimiento en términos de tiempo de ejecución de los métodos para encontrar altura y los métodos para encontrar burbujas, la estimación de estos tiempos se realizó en 2 computadores: el computador portátil descrito en el capítulo 4 y un computador de escritorio con las características mostradas en la tabla 5-11.

**Tabla 5-11:** Características del computador de escritorio

| Característica    | Descripción         |
|-------------------|---------------------|
| Marca             | HP                  |
| Procesador        | Core i5, 8va gen    |
| Tarjeta gráfica   | NA                  |
| Memoria RAM       | 4 GB DDR4           |
| Almacenamiento    | 1TB                 |
| Sistema operativo | Windows 10, 64 bits |

### 5.4.1. Métodos para estimar altura

Para los métodos que permiten estimar la altura se determinó el promedio de tiempo que tarda cada método en estimar la altura de 36 imágenes; los resultados se muestran en la tabla 5-12. A pesar de que con los métodos 3D no se obtuvieron resultados satisfactorios, se observa que toman la tercera parte de tiempo que toma el método 2D, pues no hay intervención humana.

**Tabla 5-12:** Tiempo de ejecución promedio métodos de para estimar altura

| Método          | Tiempo prom PC1 (seg) | Tiempo prom PC2 (seg) |
|-----------------|-----------------------|-----------------------|
| Método 2D       | 102.5                 | 108.2                 |
| Método 3D (SGM) | 39.5                  | 42.1                  |
| Método 3D (BM)  | 34.2                  | 35.6                  |

### 5.4.2. Métodos para encontrar burbujas

Para cada uno de los métodos implementados para encontrar burbujas se estimó el promedio de tiempo que tarda cada uno de los métodos en procesar cada una de las imágenes descritas en el capítulo 5. Los resultados se muestran a continuación

**Tabla 5-13:** Tiempo de ejecución promedio en segundos de métodos para encontrar burbujas

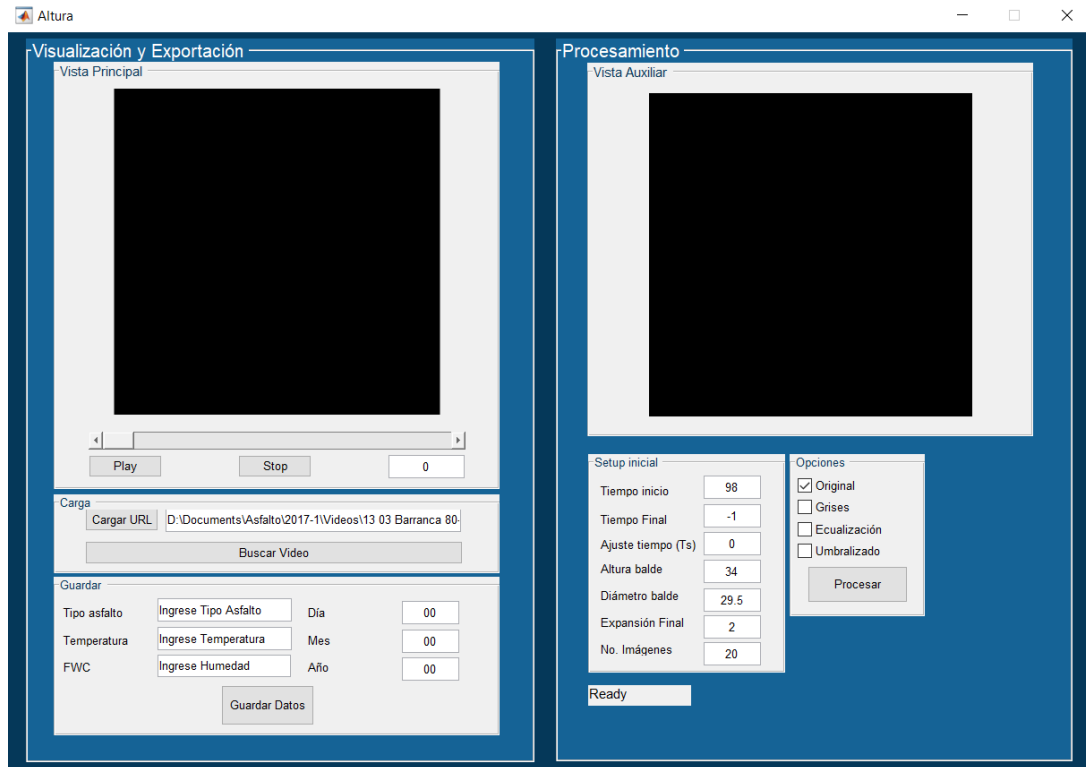
| Video        | Tiempo | Método 1 |      | Método SVM |      | Método NN |      |
|--------------|--------|----------|------|------------|------|-----------|------|
|              |        | PC 1     | PC 2 | PC 1       | PC 2 | PC 1      | PC 2 |
| 80-100 170°C | 25     | 36.3     | 37.0 | 5.9        | 6.1  | 7.1       | 7.3  |
|              | 50     | 45.8     | 46.3 | 6.6        | 6.7  | 7.9       | 8.1  |
|              | 80     | 60.3     | 62.1 | 7.6        | 7.6  | 8.1       | 8.6  |
| 60-70 160°C  | 5      | 44.4     | 44.8 | 6.0        | 6.2  | 6.5       | 7.3  |
|              | 20     | 55.7     | 56.9 | 6.9        | 7.4  | 7.5       | 8.2  |
|              | 50     | 64.0     | 66.1 | 7.9        | 8.6  | 8.5       | 9.2  |

Se evidencia que los métodos que implementan ML para clasificar las regiones encontradas con el algoritmo MSER, tienen un mejor rendimiento que el método 1, el cual clasifica dichas regiones teniendo en cuenta el criterio temporal que establece la cantidad de cuadros en la que debe permanecer una región para ser considerada burbuja. Adicionalmente se encontró que a medida que el tiempo aumenta los métodos tardan más en procesar una imagen, esto se debe a que la cantidad de burbujas aumenta con el tiempo y por ende la cantidad de regiones que los distintos métodos tienen que procesar.

Al implementar los distintos métodos en 2 computadores se observa que hay diferencias entre los tiempos de ejecución promedio, pues en el computador de escritorio los tiempos son mayores, sin embargo las diferencias son menores a 5 segundos. Al momento de implementar la herramienta desarrollada se recomienda que el computador tenga características similares a los usados en este trabajo.

## 5.5. Interfaz gráfica

Para el desarrollo de la interfaz gráfica se hizo uso de la herramienta *GUIDE* de Matlab [31, 32]. La interfaz gráfica se desarrolló en dos partes, una parte implementa el método 2D para estimar altura y la otra parte implementa los métodos para encontrar burbujas. En la figura 5-24 se muestra la interfaz creada para estimar la curva de colapso y por ende ER y HL y en la figura 5-26 se muestra la interfaz creada para la detección de burbujas y estimación de la BSD.



**Figura 5-24:** Interfaz gráfica para estimar Curva de Colapso, ER y HL

La interfaz de altura tiene las siguientes funcionalidades:

- Para la carga de un video, puede hacerse a través de una URL o una búsqueda directa mediante el explorador de archivos. En caso de usar URL, esta debe contener ruta, el nombre y extensión del archivo de video que se quiere procesar  
Ejemplo: D:\Documents\Asfalto\160-25.avi
- Permite reproducir, pausar o detener el video en la vista principal y además tiene una visualización adicional que puede ser en niveles de gris, la ecualización de histograma de la imagen actual o umbralización mediante otzu.
- Permite procesar el video con el método 2D, pero debe ingresarse como mínimo el tiempo de inicio y final, así como la cantidad de imágenes que se desean procesar
- Una vez se ha realizado el procesamiento del video, la herramienta permite guardar los resultados. Se definió un formato para presentar la información, el cual establece que el nombre de los archivos debe contener la fecha, tipo



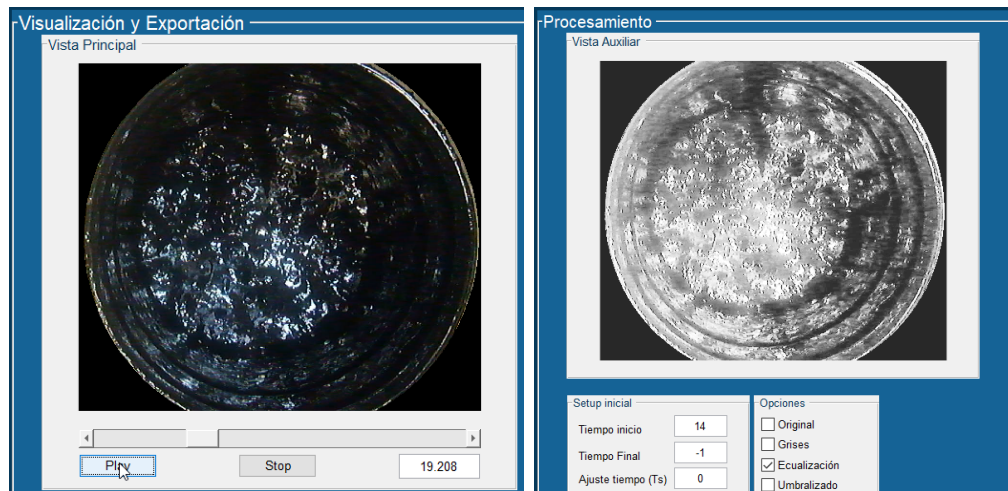
de asfalto, temperatura y humedad usados, por lo que se debe ingresar esta información antes de guardar los resultados.

Ejemplo de formato : 15-07-20\_80-100\_170-2,5


Fecha: 15 de Julio de 2020, Tipo de asfalto: MPI 80-100, Temperatura 170°C y Humedad 2.5 %.

Se genera un archivo con extensión .mat y otro con extensión .xlsx que contienen el conjunto de puntos de (tiempo, altura) y los valores de ER y HL, además se genera una imagen con la curva de colapso.

En la siguiente figura se presentan algunas capturas de las funcionalidades mencionadas



(a) Reproducción de video en vista principal (b) Vista auxiliar con ecualización de histograma



(c) Guardar resultados

(d) Generación de archivos


**Figura 5-25:** Capturas de funcionalidades interfaz de Curva de Colapso

La interfaz de las burbujas tiene las siguientes funcionalidades

- Al igual que en la interfaz de altura se puede cargar un video, a través de una URL o una búsqueda directa mediante el explorador de archivos.

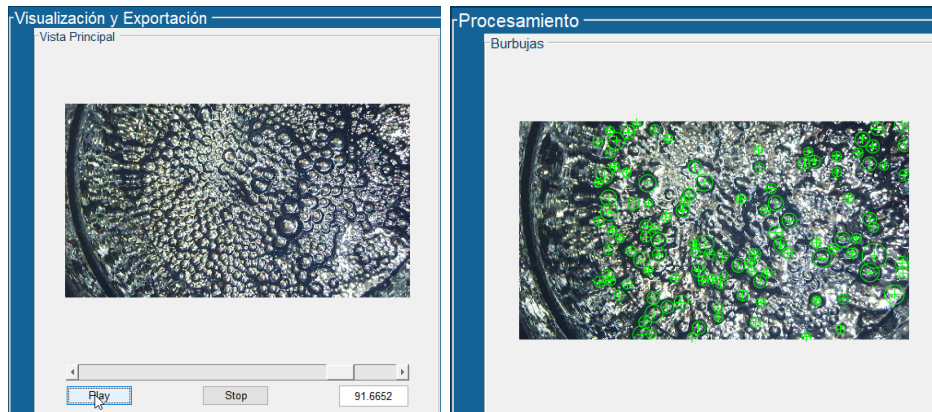
- Permite reproducir, pausar o detener el video en la vista principal.
- Permite procesar una imagen, para encontrar las burbujas y determinar la BSD, para esto debe ingresarse el tiempo en segundos del frame que se quiere procesar. La herramienta permite hacer ajustes al proceso en términos del contraste, realce de bordes, método a usar y modificación de parámetros propios de los algoritmos.
- Una vez se ha realizado el procesamiento de la imagen, se muestra la imagen con las burbujas encontradas y la BSD. La herramienta permite guardar los resultados manteniendo los formatos mencionados anteriormente.

Se genera un archivo con extensión .mat y otro con extensión .xlsx que contienen los diámetros de las burbujas, además se generan 2 imágenes: una con las burbujas encontradas y otra con la BSD.




**Figura 5-26:** Interfaz gráfica para encontrar burbujas y estimar la BSD


En la siguiente figura se presentan algunas capturas de las funcionalidades mencionadas.



(a) Reproducción de video en vista principal  
(b) Vista auxiliar con burbujas encontradas



(c) Guardar resultados



(d) Generación de archivos

**Figura 5-27:** Capturas de funcionalidades interfaz de burbujas

## 6. Conclusiones y recomendaciones

En este capítulo se concluye sobre el cumplimiento de los objetivos propuestos de acuerdo con los resultados obtenidos y se responde a la pregunta de investigación. De igual forma se hacen varias recomendaciones para la mejora y la continuación del proyecto con el fin de mejorar los métodos para encontrar la curva de colapso, así como la ER y HL y la BSD.

### 6.1. Conclusiones

El primer objetivo específico que se planteó fue la definición del sistema de adquisición y procesamiento de las imágenes. Este objetivo fue logrado al elegir que el procesamiento se realizaría en un computador y al realizar la búsqueda y selección del equipo de adquisición de las imágenes. Lo anterior se ha ido abordando a lo largo del documento, particularmente en los capítulos 4 y 5.

El segundo, tercer y quinto objetivo específico planteado fue el establecimiento de criterios para evaluar los métodos o algoritmos a implementar con el fin de estimar profundidad y detectar burbujas, así como la implementación y evaluación de estos métodos. Los métodos fueron implementados y evaluados en el capítulo 5, donde se evidenció que el método 2D para determinar la curva de colapso, ER y HL es válido y que el método con mejor desempeño para encontrar burbujas es el método que implementa una SVM como clasificador.

El cuarto y sexto objetivo específico consistía en establecer los formatos para la presentación de los resultados y la implementación de la interfaz gráfica; el cumplimiento de esto se dio en la implementación de la interfaz gráfica que permite exportar los datos adquiridos en el procesamiento.

El sexto objetivo específico planteado fue la comparación del rendimiento de la implementación de los algoritmos al momento de implementarlo en el sistema de procesamiento. Para dar cumplimiento a este objetivo se estimó el tiempo promedio que tardan los métodos en ejecutarse en dos computadores, estos resultados se muestran en el capítulo 5.

El objetivo general planteado es desarrollar una aplicación para estimar los parámetros de relación de expansión, vida media, la curva de colapso y la distribución del

tamaño de burbujas mediante visión estereoscópica, para que el laboratorio de suelos de Ingeniería Civil de la Escuela Colombiana de Ingeniería Julio Garavito mejore la caracterización de asfaltos espumados. El desarrollo de la aplicación que estimara los cuatro parámetros mencionados se logró satisfactoriamente, aunque el método implementado que consistía en la estimación de altura haciendo uso de la disparidad que existe entre las 2 cámaras no funcionó adecuadamente, por lo que en general se puede decir que para la estimación de los parámetros no se usa la información de las 2 cámaras.

El método de disparidad no funcionó debido a que este método se basa en la diferencia de los niveles de intensidad de puntos coincidentes en las imágenes y para este caso la intensidad cambia constantemente debido a la forma en que la luz es reflejada en la superficie de la espuma y en la superficie de las burbujas. Adicionalmente la distancia a la que se tomaron los videos está en el rango de pobre desempeño por la distancia entre las cámaras.

Los métodos para encontrar burbujas basados en técnicas de ML, arrojaron buenos resultados en el sentido de que las regiones clasificadas como burbujas, realmente son burbujas en su mayoría, lo que lleva a concluir que las características que extrae el algoritmo SURF a partir de las regiones MSER son representativas, pero debido a que se encontró que la eficacia de estos métodos está entre el 50 % y 60 % cuando se compara con identificaciones realizadas por un observador, estos métodos pueden ser mejorados depurando y fortaleciendo el conjunto de características con el que se realiza el entrenamiento.

Aunque los resultados indican que el método para encontrar burbujas con menor desempeño es el método 1, el cual fue desarrollado en toda su extensión con técnicas de procesamiento de imágenes, este presenta un desempeño cercano al desempeño de los métodos que usan ML y naturalmente es susceptible de mejoras tanto en la etapa de preprocesamiento como en la etapa de procesamiento de imágenes.

Por último, por las características propias de la superficie del asfalto y de las burbujas es difícil tener una iluminación uniforme, lo que causa detección errónea de burbujas en todos los métodos implementados para encontrar burbujas y dificulta la identificación del diámetro visible de la espuma en el método 2D para estimar altura. Con un trabajo experimental que defina la iluminación más adecuada, incluso recurriendo a la iluminación estructurada, seguramente los resultados pueden ser mejores.

## 6.2. Recomendaciones

El desarrollo de este trabajo deja una base de conocimiento y experiencia que pueden ayudar a mejorar el desempeño de los distintos métodos implementados e incluso a aventurar en la implementación de nuevas técnicas en un trabajo posterior.

Inicialmente se recomienda presentar las aplicaciones al Laboratorio de Suelos y Pavimentos, para establecer oportunidades de mejora y determinar cual es el patrón de referencia en altura y en burbujas, para luego realizar pruebas con los métodos desarrollados y validar su funcionamiento con otras espumas asfálticas. De igual manera se debe capacitar a los operarios en el uso de la herramienta desarrollada.

Se recomienda realizar un trabajo experimental que defina la iluminación más adecuada para la toma de imágenes en espumas asfálticas, evitar sombras causadas por el movimiento de las personas involucradas en la captura de las imágenes, pues cuando la intensidad lumínica es alta ocasiona saturación en regiones de las imágenes que posteriormente inciden en errores en la implementación de los distintos métodos.

El método 2D puede mejorarse e incluso usarse en otras aplicaciones de estimación de profundidad, para lo cual se recomienda fijar la cámara de tal manera que se enfoque bien la escena, pero que adicionalmente el o los objetos de referencia se reconozcan claramente en la imagen. En general debe realizarse un proceso de calibración de la cámara y más aún si se observan deformaciones en las imágenes.

Realizar la estimación de altura mediante otro tipo de sensor como por ejemplo sensores basados en *Time Of Flight* (TOF), sensores láser o ultrasonido de tipo industrial, de tal manera que el procesamiento de imágenes pueda enfocarse en la estimación de la distribución del tamaño de burbujas.

Los métodos para detección de burbujas son susceptibles de mejoras, particularmente el método basado en procesamiento de imágenes, por lo que se recomienda realizar un trabajo en donde se refinen las etapas de preprocesamiento y procesamiento de imágenes. En el caso de los métodos basados en *machine learning* se recomienda realizar una evaluación de características adicionales a las entregadas por el algoritmo SURF, que ayuden a mejorar el rendimiento de estos métodos, esas características adicionales pueden ser textura, pixeles vecinos e incluso otros descriptores que extraigan características de las regiones de interés.

# Referencias Bibliográficas

- [1] ABREU, L. P. F. ; OLIVEIRA, J. R. M. ; SILVA, H. M. R. D. ; PALHA, D. ; FONSECA, P.V.: Suitability of different foamed bitumens for warm mix asphalts with increasing recycling rates. En: *Construction and Building Materials* 142 (2017), p. 342–353
- [2] ALAGOZ, B.: Obtaining Depth Maps From Color Images By Region Based Stereo Matching Algorithms. En: *OncuBilim Algorithm And Systems Labs* 8 (2008)
- [3] APEAGYEI, A.: Evaluating Foamed Asphalt Stability Using Acoustic Emission Techniques. En: *Materials in Civil Engineering* 25 (2012), p. 1291–1298
- [4] AREGA, Z. A. ; BHASIN, A. ; LI, W. ; NEWCOMB, D. E. ; ARAMBULA, E.: Characteristics of Asphalt Binders Foamed in the Laboratory to Produce Warm Mix Asphalt. En: *Materials in Civil Engineering* 26 (2014), p. 1–10
- [5] BAY, H. ; TUYTELAARS, T. ; VAN GOOL, L.: SURF: Speeded Up Robust Features. En: *Computer Vision - ECCV 2006*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2006. – ISBN 978-3-540-33833-8, p. 404–417
- [6] BAY, H. ; TUYTELAARS, T. ; VAN GOOL, L.: Speeded-Up Robust Features (SURF). En: *Computer Vision and Image Understanding* 110 (2008), p. 346–359
- [7] BOUGUET, J. Y. *Camera Calibration Toolbox for Matlab*. En: [http://www.vision.caltech.edu/bouguetj/calib\\_doc/](http://www.vision.caltech.edu/bouguetj/calib_doc/). Consultado en Febrero 2020
- [8] BROWN, M. Z. ; BURSCHKA, D. ; HAGER, G.D.: Advances in computational stereo. En: *Pattern Analysis and Machine Intelligence* 25 (2003), p. 993–1008
- [9] CAMPAGNOLI, S. ; ESTUPIÑAN, E. ; PARRA, O. ; PUENTES, D. ; ALVAREZ, A. ; REYES, O.: Aplicación del procesamiento de imágenes para evaluar el colapso y el tamaño de burbujas de espumas de asfalto. En: *Memorias XIX CILA*, 2017

- [10] CANCINO, S. ; ESTUPIÑAN, E. ; MORENO, H. *Documento técnico del proyecto "Desarrollo de una aplicación en móviles como herramienta de ayuda a invidentes"*. Consultado en Junio de 2019. 2013
- [11] CHATZIS, S. P. ; SIAKOULIS, V. ; PETROPOULOS, A. ; STAVROULAKIS, E. ; VLACHOGIANNAKIS, N.: Forecasting stock market crisis events using deep and statistical machine learning techniques. En: *Expert Systems With Applications* 112 (2018), p. 353–371
- [12] CRAZE, Reading. *Research Designs: Non-Experimental vs. Experimental*. En: <http://readingcraze.com/index.php/research-design-experimental-nonexperimental/>. Consultado en Febrero 2020
- [13] EAPA. *The use of Warm Mix Asphalt*. En: [http://www.eapa.org/userimg/position paper/the use of warm mix asphalt.pdf](http://www.eapa.org/userimg/position%20paper/the%20use%20of%20warm%20mix%20asphalt.pdf). 2010
- [14] EVANS, D. ; GRUBA, P. ; ZOBEL, J.: *How to Write a Better Thesis*. 3. Australia : Springer, 2014. – ISBN 978–3–319–04285–5
- [15] HAILESILASSIE, B. ; SCHUETZ, P. ; JERJEN, I. ; BIEDER, A. ; HUGENER, M. ; PRATL, M.: Evolution of bubble size distribution during foam bitumen formation and decay. En: *Asphalt Pavements - Proceedings of the International Conference on Asphalt Pavements*. Raleigh, North Carolina, 2014, p. 1233–1240
- [16] HASTIE, T. ; TIBSHIRANI, R. ; FRIEDMAN, J.: *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. Birmingham : Springer, 2009. – ISBN 978–1–78355–513–0
- [17] HASTIE, T. ; TIBSHIRANI, R. ; FRIEDMAN, J.: Unsupervised learning. En: *The elements of statistical learning, Springer* (2009), p. 485–585
- [18] HE, G. ; WONG, W.: Decay properties of the foamed bitumens. En: *Materials in Civil Engineering* 25 (2012), p. 1291–1298
- [19] HIRSCHMULLER, H.: Accurate and Efficient Stereo Processing by Semi-Global Matching and Mutual Information. En: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2005, p. 807–814
- [20] IMAH, E. M. ; WIDODO, A.: A comparative study of machine learning algorithms for epileptic seizure classification on EEG signals. En: *2017 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, 2017, p. 401–408



- [21] JOGLEKAR, A. ; JOSHI, D. ; KHEMANI, R. ; NAIR, S. ; SAHARE, S.: Depth estimation using monocular camera. En: *Computer science and information technologies 2* (2011), p. 1758–1763
- [22] KLUYTMANS, J. H.: An airlift loop redox cycle reactor for alcohol oxidations: Hydrodynamics, mass transfer and reactor design. En: *Knowledge, Technology and Policy* (2003)
- [23] KONOLIGE, K.: Small Vision Systems: Hardware and Implementation. En: *Proceedings of the 8th International Symposium in Robotic Research*, 1997, p. 203–212
- [24] KUMARI, D. ; KAUR, K.: A Survey on Stereo Matching Techniques for 3D Vision in Image Processing. En: *International Journal of Engineering and Manufacturing* 6 (2016), p. 40–49
- [25] LEWIS, C.: Ventajas de tener vías 4g en el país. En: *Portafolio* (2016)
- [26] LIN, B. ; RECKE, B. ; KNUDSEN, J. K. H. ; JORGENSEN, S. B.: Bubble size estimation for flotation processes. *Minerals Engineering*. En: *Minerals Engineering* 21 (2008), p. 539–548
- [27] LIN, Y. ; WANG, C. ; JUNG, T. ; WU, T. ; JENG, S. ; DUANN, J. ; CHEN, J.: EEG-Based Emotion Recognition in Music Listening. En: *IEEE Transactions on Biomedical Engineering* 57 (2010), p. 1798–1806
- [28] LINDBERG, T.: Feature Detection with Automatic Scale Selection. En: *International Journal of Computer Vision* 30 (1998), p. 79–116
- [29] LOWE, D.G.: Distinctive Image Features from Scale-Invariant Keypoints. En: *International Journal of Computer Vision* 60 (2004), p. 91–110
- [30] MATAS, J. ; CHUM, O. ; URBAN, M. ; PAJDLA, T.: Robust wide-baseline stereo from maximally stable extremal regions. En: *Image and Vision Computing* 22 (2004), p. 761–767
- [31] MATHWORKS. *Crea una aplicación sencilla usando GUIDE*. En: [https://la.mathworks.com/help/matlab/creating\\_guis/about-the-simple-guide-gui-example.html](https://la.mathworks.com/help/matlab/creating_guis/about-the-simple-guide-gui-example.html). Consultado en Enero 2019
- [32] MATHWORKS. *How to Create a GUI with GUIDE*. En: <https://la.mathworks.com/videos/creating-a-gui-with-guide-68979.html>. Consultado en Enero 2019

- [33] MATHWORKS. *reconstructScene*. En: <http://readingcraze.com/index.php/research-design-experimental-nonexperimental/>. Consultado en Febrero 2020
- [34] MATHWORKS. *Classify Patterns with a Shallow Neural Network*. En: <https://la.mathworks.com/help/deeplearning/gs/classify-patterns-with-a-neural-network.html>. Consultado en Junio 2020
- [35] MATHWORKS. *Train Classification Models in Classification Learner App*. En: <https://la.mathworks.com/help/stats/train-classification-models-in-classification-learner-app.html?lang=en>. Consultado en Junio 2020
- [36] MATHWORKS. *Stereo Camera Calibrator App*. En: <https://la.mathworks.com/help/vision/ug/stereo-camera-calibrator-app.html>. Consultado en Mayo 2020
- [37] MAYBANK, S. J. ; FAUGERAS, O. D.: A theory of self-calibration of a moving camera. En: *International Journal of Computer Vision* 8 (1992), p. 123–151
- [38] MIKOLAJCZYK, K. ; SCHMID, C.: An Affine Invariant Interest Point Detector. En: *Computer Vision - ECCV 2002*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2002. – ISBN 978-3-540-47969-7, p. 128–142
- [39] MISRA, N. ; PHALAK, R. ; MARTYNYENKO, A.: A microscopic computer vision algorithm for autonomous bubble detection in aerated complex liquids. En: *Journal of Food Engineering* 238 (2018), p. 54–60
- [40] MOMENIK, M. ; DIAMANTAS, S. C. ; RUGGIERO, F. ; SICILIANO, B.: Height Estimation from a Single Camera View. En: *Proceedings of the International Conference on Computer Vision Theory and Applications* Vol. 1, 2012, p. 358–364
- [41] MOUJAHID, A. ; INZA, I. ; LARRAÑAGA, P. *Tema 5. Clasificadores K-NN*. En: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t9knn.pdf>. Consultado en Junio 2020
- [42] NAVARRO, F. ; CANCINO, S. ; ESTUPIÑAN, E.: Depth Estimation for Visually Impaired People Using Mobile Devices. En: *2014 IEEE 5th Latin American Symposium on Circuits and Systems*, 2014, p. 1–4
- [43] NEWCOMB, D. E. ; ARAMBULA, E. ; YIN, F. ; ZHANG, J. ; BHASIN, A. ; LI, W. ; AREGA, Z.: *Properties of Foamed Asphalt for Warm Mix Asphalt Applications*. 1. Washington, D.C. : Transportation Research Board, 2015. – ISBN 978-0-309-30866-3

- [44] OPENCV. *Camera calibration With OpenCV*. En: <https://docs.opencv.org/2.4/doc/tutorials/calib3d/camera-calibration/camera-calibration.html>. Consultado en Diciembre 2019
- [45] OPENCV. *Depth Map from Stereo Images*. En: <https://docs.opencv.org/3.1.0/dd/d53/tutorial-py-depthmap.html>. Consultado en Diciembre 2019
- [46] OPENCV. *Epipolar Geometry*. En: <https://docs.opencv.org/master/da/de9/tutorial-py-epipolar-geometry.html>. Consultado en Diciembre 2019
- [47] OTTEN, P. ; KIM, J. ; SON, S. H.: A Framework to Automate Assessment of Upper-Limb Motor Function Impairment: A Feasibility Study. En: *Sensors* 15 (2015), p. 20097–20114
- [48] PATRAUCEAN, V.: *Detection and identification of elliptical structure arrangements in images: theory and algorithms*, UNIVERSITY OF TOULOUSE, PHD Thesis, 2012
- [49] PAZ, B. ; CONDE, M. ; PORTEIRO, J. ; CONCHEIRO, M.: On the Application of Image Processing Methods for Bubble Recognition to the Study of Subcooled Flow Boiling of Water in Rectangular Channels. En: *Sensors* 17 (2017)
- [50] PISAPIA, R.: *Disparity map extraction for a low cost 3D sensor*, Università degli Studi di Salerno, Université de Lorraine, Tesis de Grado, 2015
- [51] RASCHKA, S.: *Python Machine Learning*. 1. Birmingham : Packt Publishing Ltd, 2015. – ISBN 978–1–78355–513–0
- [52] RECUERO, P. *Tipos de aprendizaje en Machine Learning: supervisado y no supervisado*. En: <https://empresas.blogthinkbig.com/que-algoritmo-elegir-en-ml-aprendizaje/>. 2017
- [53] REMONDINO, F. ; FRASER, C.: Digital camera calibration methods: Considerations and comparisons. En: *Ine. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 36 (2005), 11
- [54] SCHARSTEIN, D. ; SZELISKI, R.: A Taxonomy and Evaluation of Dense Two-Frame Stereo Correspondence Algorithms. En: *Proceedings IEEE Workshop on Stereo and Multi-Baseline Vision (SMBV 2001)*, 2001, p. 131–140

- [55] SEAL, J. ; BAILEY, D. ; SENGUPTA, G.: Depth perception with a single camera. En: *1st International Conference on Sensing Technology* Vol. 1. Palmerston North, New Zealand, 2005, p. 96–101
- [56] SEMENIUTA, O.: Analysis of camera calibration with respect to measurement accuracy. En: *48th CIRP Conference on MANUFACTURING SYSTEMS* (2016), p. 765–770
- [57] SHALEV-SHWARTZ, S. ; BEN-DAVID, S.: *Understanding machine learning: From theory to algorithms*. 1. New York : Cambridge University Press, 2014. – ISBN 978–1107057135
- [58] SIMENONE, O. *A Very Brief Introduction to Machine Learning With Applications to Communication Systems*. <https://arxiv.org/pdf/1808.02342.pdf>. 2018
- [59] SOLOMON, C. ; BRECKON, T: *Fundamentals of digital image processing: A practical approach with examples in Matlab*. 1. Wiley-Blackwell, 2011. – ISBN 978–0–470–84472–4
- [60] SOLUTION, Statistics. *Research Design: Experimental and Non-experimental Research*. En: <https://www.statisticssolutions.com/research-designs-non-experimental-vs-experimental/>. Consultado en Febrero 2020
- [61] SZELISKI, R. C.: *Computer Vision: Algorithms and Applications*. 1. London : Springer, 2010. – ISBN 978–1–84882–935–0
- [62] SZELISKI, R. C. ; WOODS, R. E.: *Digital Image Processing*. 3. Saddle River, New Jersey : Pearson Prentice Hall, 2008. – ISBN 978–0–13–168728–8
- [63] THENOUX, G. J. ; JAMET, A.: Tecnología del asfalto espumado y diseño de mezcla. En: *Revista Ingeniería de Construcción Pontificia Universidad Católica de Chile* (2002)
- [64] TSAI, R.: A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses. En: *IEEE Journal on Robotics and Automation* 3 (1987), p. 323–344
- [65] TYAGI, D. *Introduction to SURF (Speeded-Up Robust Features)*. En: <https://medium.com/data-breach/introduction-to-surf-speeded-up-robust-features-c7396d6e7c4e>. Consultado en Junio 2020

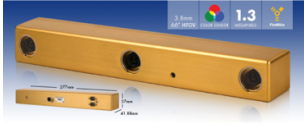

- 
- [66] UNIPYTHON. *Calibración de la cámara Opencv.* En: <https://unipython.com/calibracion-la-camara-opencv/>. Consultado en Diciembre 2019
- [67] VEKSLER, O.: Stereo correspondence by dynamic programming on a tree. En: *IEEE International Conference on Computer Vision and Pattern Recognition* (2005), p. 384–390
- [68] ZHANG, Z.: A flexible new technique for camera calibration. *Pattern Analysis and Machine Intelligence*. En: *IEEE Transactions* 22 (2000), p. 1330–1334
- [69] ZHANG, Z.: Camera calibration with one-dimensional objects. En: *IEEE transactions on pattern analysis and machine intelligence* 26 (2004), p. 892–899
- [70] ZITNICK, C. ; KANADE, T.: A Cooperative Algorithm for Stereo Matching and Occlusion Detection. En: *Pattern Analysis and Machine Intelligence* 22 (2000), p. 675–684




# A. Anexo: Evaluación de equipos de adquisición de imágenes


A continuación se presenta una tabla con algunos de los dispositivos que se consideraron para llevar a cabo la tarea de adquisición de imágenes.

Comercialmente existen diversos tipos de dispositivos con arreglos de varios tipos de sensores que no se consideraron debido a que desde la concepción del proyecto se pensó en realizar la implementación mediante una cámara 3D que pudiera servir para otras aplicaciones.

**Tabla A-1:** Evaluación de equipos para adquisición de imágenes

| Imagen  | Nombre                      | Descripción   | Evaluación  |
|---|-----------------------------|---|---|
|  | Bumblebee XB3               | Sensor CCD. Rango de hasta 2m. Resolución 1280x960 a 16 Fps. Interfaz de comunicación RS-232. Precio: 3500 USD                  | Cumple con los criterios de resolución espacial y Fps, pero se descarta por el precio.  |
|  | FinePix REAL 3D W3 FUJIFILM | Sensor CCD. Resolución 1280x720 a 24 Fps. Interface de comunicación HDMI-mini terminal. Almacenamiento interno. Precio: 500 USD | Cumple con los criterios de resolución espacial y Fps, posee almacenamiento interno, posee zoom digital y aunque el precio es un poco alto es una buena opción. |

|   |                    |   |   |
|---|--------------------|---|---|
|    | DUO MC             | <p>Rango de medida 0.076-1.9m.<br/>Resolución 752x480 a 45 Fps. Precisión de 0.15cm.<br/>Interfaz de comunicación USB Mini-B. Precio: 625 USD</p> | <p>No cumple con el requerimiento de resolución espacial por lo que no es adecuado para la detección de burbujas. No cuenta con almacenamiento interno por lo que requeriría un sistema adicional para la captura y almacenamiento de las imágenes.</p> |
|  | LG Optimus 3D P920 | <p>Resolución 1280x720 a 30 Fps. Almacenamiento externo en memoria micro SD. Precio: 140 USD</p>  | <p>Cumple con los criterios de resolución espacial y Fps, posee almacenamiento interno y el precio es bajo. Es una buena opción.</p>  |
|  | HTC EVO 3D         | <p>Resolución 1280x720 a 30 Fps. Almacenamiento externo en memoria micro SD. Precio: 120 USD</p>  | <p>Cumple con los criterios de resolución espacial y Fps, posee almacenamiento interno y el precio es bajo. Es una buena opción.</p>  |

|  |                   |  |   |
|--|-------------------|--|---|
|  A black Kinect v1 sensor with three lenses and a green light indicator, mounted on a black base. The word "KINECT" is visible on the right side of the sensor. | Kinect mi-crosoft | Cuenta con una cámara RGB con resolución 1280x960 a 30 Fps, sensor infra rojo, 3 acelerómetros. Rango 1.2m a 5m. Precio: 400 USD | Cumple con los criterios de resolución espacial y Fps, no cuenta con almacenamiento interno y por el rango de funcionamiento puede no ser una buena opción para las burbujas. |
|--|-------------------|--|---|



## B. Anexo: Relación entre p2cm y Altura

Con el fin de obtener la altura de la espuma usando la geometría de la escena y teniendo en cuenta el trabajo realizado en [40], se realizaron mediciones del diámetro en pixeles para distintas alturas con lo que se obtuvo los resultados mostrados en la tabla B-1

Tabla B-1: Datos medidos

| Altura real | Radio Real | Radio en pixeles | p2cm   |
|-------------|------------|------------------|--------|
| 34          | 14.5       | 1073             | 0.0135 |
| 25          | 14.5       | 880              | 0.0165 |
| 18          | 14.5       | 767              | 0.0189 |
| 15          | 14.5       | 731              | 0.0198 |
| 12          | 14.5       | 686              | 0.0211 |
| 9           | 14.5       | 658              | 0.0220 |
| 6           | 14.5       | 634              | 0.0229 |
| 3           | 14.5       | 605              | 0.0240 |

Si se asume que el plano de la cámara es paralelo al plano del piso y por ende al plano en el que se encuentra la espuma, se puede obtener una relación entre pixeles y centímetros (p2cm) al tomar el radio real del balde y dividirlo en el radio en pixeles de la espuma en un instante de tiempo determinado. Al graficar altura contra p2cm (ver figura B-1) se evidencia que hay una relación lineal. En la tabla B-2 se muestran los resultados obtenidos al aplicar una regresión lineal junto con el respectivo análisis de varianza con ayuda del paquete estadístico de excel. Puesto que el valor p obtenido es cercano a 0 se puede concluir que el modelo es significativo y explica bien los datos pues el coeficiente de determinación es muy cercano a 1.

Tabla B-2: Regresión y ANOVA de la regresión


| Resumen                                      |            |
|--|------------|
| <i>Estadísticas de la regresión</i>          |            |
| Coefficiente de correlación múltiple         | 0.9996003  |
| Coefficiente de determinación R <sup>2</sup> | 0.99920077 |
| R <sup>2</sup> ajustado                      | 0.99906756 |
| Error típico                                 | 0.31385546 |
| Observaciones                                | 8          |

| ANÁLISIS DE VARIANZA |                    |                   |                           |            |                    |
|----------------------|--------------------|-------------------|---------------------------|------------|--------------------|
|                      | Grados de libertad | Suma de cuadrados | Promedio de los cuadrados | F          | Valor crítico de F |
| Regresión            | 1                  | 738.908969        | 738.908969                | 7501.21425 | 1.5959E-10         |
| Residuos             | 6                  | 0.59103149        | 0.09850525                |            |                    |
| Total                | 7                  | 739.5             |                           |            |                    |

|              | Coefficientes | Error típico | Estadístico t | Probabilidad | Inferior 95% | Superior 95% | Inferior 95.0% | Superior 95.0% |
|--------------|---------------|--------------|---------------|--------------|--------------|--------------|----------------|----------------|
| Intercepción | 73.7785463    | 0.68482454   | 107.733502    | 4.3113E-11   | 72.102841    | 75.4542516   | 72.102841      | 75.4542516     |
| p2cm         | -2949.60835   | 34.0563868   | -86.6095506   | 1.5959E-10   | -3032.94133  | -2866.27538  | -3032.94133    | -2866.27538    |



**Figura B-1:** Relación entre altura y p2cm

## C. Anexo: Parámetros de los modelos teóricos

En la siguiente tabla se muestran los parámetros de los modelos teóricos proporcionados por el laboratorio de suelos y pavimentos

**Tabla C-1:** Tabla de parámetros de modelos teóricos

| T(°C) | % agua | Parámetros |          |          |          |          |          |          |          |          |
|-------|--------|------------|----------|----------|----------|----------|----------|----------|----------|----------|
|       |        | a          | b        | c        | d        | f        | g        | h        | j        | k        |
| 140   | 1.5    | 5.130237   | 33.01786 | 5.130237 | 33.01786 | 1.124342 | 2.596021 | 8.72802  | 0.145349 | 29.14919 |
|       | 2.5    | 16.12735   | 20.88902 | 16.40698 | 20.88902 | 1.930542 | 3.165265 | 30.65691 | 0.047735 | 18.86809 |
|       | 3.5    | 14.57184   | 16.00308 | 14.57184 | 16.00308 | 3.133874 | 3.903097 | 27.60815 | 0.061955 | 15.27276 |
|       | 4.5    | 19.91858   | 13.58907 | 19.91858 | 13.58907 | 2.026147 | 2.483143 | 34.59295 | 0.066562 | 13.75551 |
| 150   | 1.5    | 8.58105    | 11.69478 | 8.615195 | 13.01775 | 2.234109 | 2.512004 | 19.94952 | 0.075023 | 9.170749 |
|       | 2.5    | 15.01882   | 10.56307 | 14.76403 | 10.56306 | 3.868815 | 4.501991 | 25.8966  | 0.136041 | 11.9272  |
|       | 3.5    | 18.97641   | 12.45221 | 18.72257 | 12.45221 | 1.358684 | 2.304315 | 33.66976 | 0.090106 | 11.8424  |
|       | 4.5    | 22.24374   | 13.00625 | 21.99016 | 13.00625 | 1.925109 | 4.761519 | 36.92685 | 0.114439 | 12.55152 |
| 160   | 1.5    | 12.30337   | 7.395622 | 11.99102 | 7.395622 | 3.609864 | 3.765117 | 22.98407 | 0.116138 | 7.787992 |
|       | 2.5    | 18.2698    | 7.924915 | 17.97041 | 7.924915 | 1.694351 | 1.731811 | 215.0951 | 0.058529 | -12.1008 |
|       | 3.5    | 21.90786   | 10.994   | 21.60847 | 10.994   | -1.88794 | 3.169023 | 32.47418 | 0.227904 | 9.559487 |
|       | 4.5    | 20.13361   | 10.66012 | 19.83506 | 10.66012 | 3.338495 | 4.294529 | 40.40412 | 0.101397 | 9.256995 |

## D. Anexo: Imágenes donde no se evidencia presencia de burbujas

A continuación se presentan algunas imágenes de los distintos videos en donde no se observan burbujas con facilidad.

En esta figura se tiene la imagen de un asfalto con 1.5% de contenido de agua, a una temperatura de 140°C. Se observa que la superficie del asfalto no es uniforme y aunque hay unas cuantas burbujas, estas no se aprecian con facilidad.



**Figura D-1:** Imagen de asfalto con 1.5% de humedad, temperatura de 140°C en  $t=30$  seg

En esta figura se tiene la imagen de un asfalto con 2.5% de contenido de agua, a una temperatura de 150°C. No se aprecian burbujas y la superficie del asfalto es lisa.



**Figura D-2:** Imagen de asfalto con 2.5 % de humedad, temperatura de 150°C en t=40 seg


En esta figura se tiene la imagen de un asfalto con 3.5 % de contenido de agua, a una temperatura de 160°C. En este video no se aprecian burbujas sino más bien depresiones o huecos sobre la superficie del asfalto.




**Figura D-3:** Imagen de asfalto con 3.5 % de humedad, temperatura de 160°C en t=20 seg

## E. Anexo: Resultados adicionales de BSD

A continuación se presentan los gráficos de los resultados obtenidos con cada método para el video MPI 60-70 con 2.5% de contenido de agua y una temperatura de 160°C.




(a) Burbujas encontradas




(b) BSD

Figura E-1: Resultados método 1 para  $t = 5$  seg




(a) Burbujas encontradas




(b) BSD

**Figura E-2:** Resultados método 1 para  $t = 20$  seg





(a) Burbujas encontradas




(b) BSD


**Figura E-3:** Resultados método 1 para  $t = 50$  seg

Tabla E-1: Resultados BSD con método 1

| Tiempo (seg) | # Burbujas | Diámetro promedio (mm) |
|--------------|------------|------------------------|
| 5            | 221        | 10.323                 |
| 20           | 274        | 10.1652                |
| 50           | 343        | 9.84296                |




(a) Burbujas encontradas

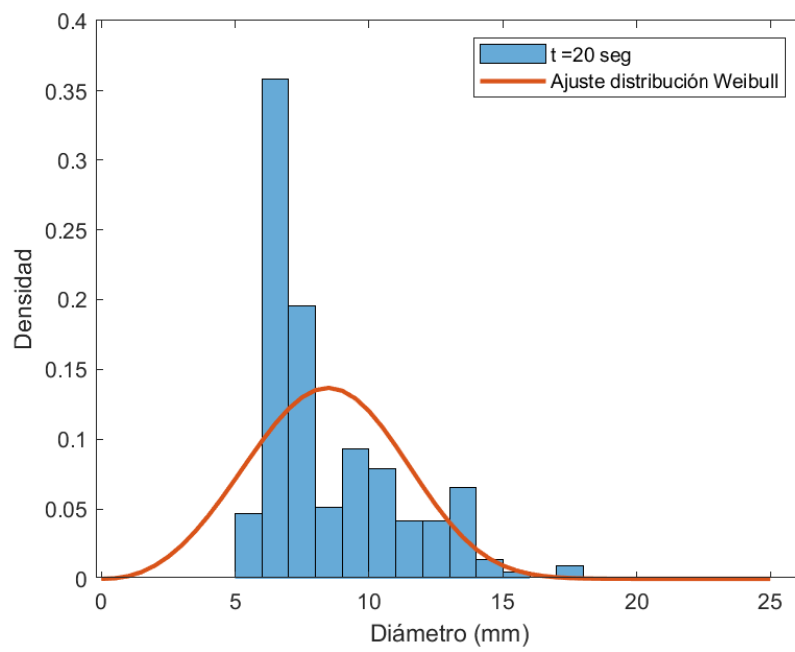


(b) BSD

Figura E-4: Resultados método SVM para  $t = 5$  seg




(a) Burbujas encontradas




(b) BSD

**Figura E-5:** Resultados método SVM para  $t = 20$  seg



(a) Burbujas encontradas




(b) BSD


**Figura E-6:** Resultados método SVM para  $t = 50$  seg

Tabla E-2: Resultados BSD con método SVM

| Tiempo (seg) | # Burbujas | Diámetro promedio (mm) |
|--------------|------------|------------------------|
| 5            | 144        | 8.9369                 |
| 20           | 215        | 8.4742                 |
| 50           | 281        | 7.8245                 |




(a) Burbujas encontradas




(b) BSD

Figura E-7: Resultados método NN para  $t = 5$  seg




(a) Burbujas encontradas




(b) BSD

**Figura E-8:** Resultados método NN para  $t = 20$  seg



(a) Burbujas encontradas



(b) BSD

**Figura E-9:** Resultados método NN para  $t = 50$  seg

**Tabla E-3: Resultados BSD con método NN**

| <b>Tiempo (seg)</b> | <b># Burbujas</b> | <b>Diámetro promedio (mm)</b> |
|---------------------|-------------------|-------------------------------|
| 5                   | 146               | 8.7968                        |
| 20                  | 207               | 8.6027                        |
| 50                  | 271               | 7.8329                        |